

**CLASSIFICAÇÃO DE DADOS LANDSAT 8 DO NORTE DE PORTUGAL  
COM RECURSO A GEOGRAPHIC OBJECT-BASED IMAGE ANALISYS  
(GEOBIA)**

**Ricardo Alexandre da Silva Caeiro**

**Dissertação de Mestrado em Gestão do Território, Especialização em  
Deteção Remota e Sistemas de Informação Geográfica**

**Outubro, 2015**

## [DECLARAÇÕES]

Declaro que esta tese Dissertação é o resultado da minha investigação pessoal e independente. O seu conteúdo é original e todas as fontes consultadas estão devidamente mencionadas no texto, nas notas e na bibliografia.

O candidato,

Ricardo Paeiro

Lisboa, 30 de Setembro de 2015

Declaro que esta Dissertação se encontra em condições de ser apreciado pelo júri a designar.

O orientador,

Prof. António F. Moreira

Lisboa, 30 de Setembro de 2015

Perfection is not attainable, but if we  
chase perfection we can catch excellence.

Vince Lombardi

## **AGRADECIMENTOS**

Um especial agradecimento ao Professor Doutor José António Tenedório, por ter aceite ser meu orientador e por me ter despertado o gosto em deteção remota. Quero agradecer toda a sua disponibilidade e apoio durante o período da dissertação e do meu percurso académico.

Um obrigado aos meus pais por me terem dado acesso a um dos meus objectivos, a passagem pelo ensino superior, e a paciência e apoio que demonstraram ao longo dos anos.

Aos amigos e colegas um obrigado pela ajuda e consideração ao longo desta dissertação.

Por ultimo, um grande agradecimento à minha namorada Diana Bica, pelo incentivo e por toda a ajuda que me dá todos os dias





## RESUMO

### CLASSIFICAÇÃO DE DADOS LANDSAT 8 DO NORTE DE PORTUGAL COM RECURSO A GEOGRAPHIC OBJECT-BASED IMAGE ANALISYS (GEOBIA)

Ricardo Alexandre da Silva Caeiro

**PALAVRAS-CHAVE:** Detecção Remota, Alta Resolução, Classificação, Segmentação, Pixel, Orientada por objetos.

A detecção remota é uma ciência e técnica, que permite recolher informação de características físicas de um objeto de uma determinada superfície através da radiação eletromagnética, sem entrar em contato com ela. É muito importante na área do planeamento e ordenamento do território e na monitorização da superfície terrestre, ajudando os atores e intervenientes do território no apoio à decisão.

A presente dissertação tem como principal objetivo a classificação de dados *Landsat 8* para o Norte de Portugal com recurso a *Geographic Object-Based Image Analysis* (GEOBIA) e explorar as suas potencialidades e limitações em imagens de baixa resolução espectral, como é o caso das novas imagens *Landsat 8*, posteriormente, comparou-se o resultado da classificação orientada a objetos com os resultados extraídos da classificação orientada pixel a pixel e segmentos, de modo a avaliar a sua exatidão global e índice de concordância *Kappa*, nesta dissertação foram usados os *software ENVI 5.0* e *eCognition 9.0*.

A classificação com melhor desempenho de exatidão de global e índice de concordância *Kappa* é a classificação orientada a objetos, com valores de 56% (14 classes) e 61% (10 classes), e 0,46 (14 classes) e 0,50 (10 classes) respetivamente.

As classificações orientadas a pixel e segmentos obtiveram valores de exatidão global de 49% (14 classes) e 57% (10 classes), 45% (14 classes) e 52% (10 classes), respetivamente. Para o índice de concordância *kappa* as classificações orientadas a pixel e segmentos obtiveram valores de 0,40 (14 classes) e 0,45 (10 classes), 0,34 (14 classes) e 0,34 (10 classes).

Posteriormente realizou-se uma nova cartografia de ocupação do solo, designada de COS 2015, com o objetivo de descobrir se a classificação orientada a objetos era prejudicada pela incerteza temática da COS 2007 ou pela diferença temporal entre a COS 2007 e a imagem *Landsat 8*. Posteriormente produziu-se os cálculos de exatidão global e índice de concordância *Kappa*, Com a exatidão global entre a classificação orientada a objetos e a COS 2007 ser de 59%, com um índice de concordância *Kappa* de 0,47. Entre a classificação orientada a objetos e a COS 2015, a exatidão global foi de 60% e o índice de concordância *Kappa* de 0,48.

## **ABSTRACT**

### **CLASSIFICATION OF LANDSAT 8 DATA FOR THE NORTH OF PORTUGAL WITH USE OF GEOGRAPHIC OBJECT-BASED IMAGE ANALISYS (GEOBIA)**

Ricardo Alexandre da Silva Caeiro

**KEYWORDS:** Remote Sensing, Very High Resolution, Classification, Segmentation, Pixel, Object-Oriented.

Remote sensing is a science and technique that allows to acquire information about physical features of an object from a particular surface, through electromagnetic radiation without any kind of physical contact with the object itself. This technique is fundamental in the field of planning and land use and also in the monitoring of the Earth's surface, helping actors and stakeholders in the decision making process. The aim of this thesis is to classify Landsat 8 data in the north of Portugal using Geographic Object-Based Image Analysis (GEOBIA) and explore its potential and limitations in low-resolution spectral images, as in the case of the new Landsat 8 images. Subsequently, the results from the objects-oriented classification was compared to the results extracted from the classicization based on pixel by pixel and segments, in order to assess their overall accuracy and kappa index. The software's used in this thesis were the ENVI 5.0 and the eCognition 9.0. The classification with better overall accuracy and Kappa index is the object-oriented classification, with values of 56% (14 classes) and 61% (10 classes) and 0.46 (14 classes) and 0.50 (10 classes), respectively. The classifications based on pixels and segments achieved overall accuracy values of 49% (14 classes) and 57% (10 classes), 45% (14 classes) and 52% (10 classes), respectively. For the concordance kappa index, the classifications based on pixels and segments achieved values of 0.40 (14 classes) and 0.45 (10 classes), 0.34 (14 classes) and 0.34 (10 classes). Afterwards, it was carried out a new mapping land cover, designated COS 2015, in order to find out if the classification based on objects was vulnerable due to the thematic uncertainty of the COS 2007 or by the time difference between the COS 2007 and the Landsat 8 image. Finally, the overall accuracy of the classification and the kappa index was calculated. The overall accuracy of the object-oriented classification and the COS 2007 was 59%, with a kappa index of 0.47. In the objects-oriented classification and the COS 2015, the overall accuracy was 60% and the Kappa index was 0.48.

# ÍNDICE

<b>1. INTRODUÇÃO E CONTEXTUALIZAÇÃO.....</b>	<b>1</b>
1.1 INTRODUÇÃO .....	1
1.2 OBJETIVOS .....	4
1.3 ESTRUTURA DA TESE .....	5
<b>2. CAPÍTULO II: CONTEXTUALIZAÇÃO TEÓRICA .....</b>	<b>7</b>
2.1 PROCESSOS CLÁSSICOS DE CLASSIFICAÇÃO DE DADOS OBTIDOS POR DETECÇÃO REMOTA .....	7
2.1.1 <i>Abordagem pixel a pixel</i> .....	7
2.1.1.1 Classificadores supervisionados .....	7
2.1.1.2 Classificadores não-supervisionados .....	8
2.1.2 <i>Abordagem orientada a segmentos</i> .....	9
2.1.3 <i>Abordagem orientada a objetos</i> .....	10
<b>3. CAPÍTULO III: GEOGRAPHIC OBJECT BASED IMAGE ANALYSIS (GEOBIA): UM NOVO PARADIGMA OU UM NOVO CONCEITO? .....</b>	<b>12</b>
<b>4. CAPÍTULO IV: METODOLOGIA E RESULTADOS .....</b>	<b>15</b>
4.1 ÁREA DE ESTUDO .....	15
4.2 DADOS .....	16
4.2.1 <i>Características do satélite Landsat 8</i> .....	17
4.3 NOMENCLATURA .....	22
4.4 FLUXOGRAMA DE PROCEDIMENTOS .....	30
4.5 FUSÃO DA IMAGEM .....	32
4.6 EXTRAÇÃO DE ELEMENTOS E CLASSIFICAÇÃO DE IMAGENS ORIENTADAS DE OBJETOS .....	35
4.6.1 <i>Extração de elementos e classificação de imagem a partir de algoritmia e Cognition</i> .....	35
4.6.1.1 Segmentação Multiresolução .....	35
4.6.1.2 Extração de elementos .....	38
4.7 CÁLCULO PARA AVALIAÇÃO DE EXATIDÃO DE TEMÁTICA .....	44
4.7.1 <i>Matriz de confusão</i> .....	45
4.7.2 <i>Índice de concordância Kappa</i> .....	46
4.7.3 <i>Cálculo da exatidão do utilizador e produtor, erro de comissão e omissão</i> .....	47
4.7.3.1 Exatidão do produtor .....	47
4.7.3.2 Exatidão do utilizador .....	48
4.7.3.3 Erro de comissão .....	48

4.7.3.4	Erro de omissão .....	48
4.8	RESULTADOS .....	49
4.8.1	<i>Resultados da abordagem pixel a pixel</i> .....	49
4.8.1.1	Resultado da classificação orientada pixel a pixel (10 classes) .....	49
4.8.1.2	Resultado da classificação orientada pixel a pixel (14 classes) .....	50
4.8.2	<i>Resultados da abordagem orientada a segmentos</i> .....	51
4.8.2.1	Resultado da classificação orientada a segmentos (10 classes) .....	51
4.8.2.2	Resultado da classificação orientada a segmentos (14 classes) .....	52
4.8.3	<i>Resultados da abordagem orientada a objetos</i> .....	53
4.8.3.1	Resultados da classificação orientada a objetos (10 classes) .....	53
4.8.3.2	Resultados da classificação orientada a objetos (14 classes) .....	54
5.	<b>CAPITULO V: DISCUSSÃO DE RESULTADOS</b> .....	55
6.	<b>CONSIDERAÇÕES FINAIS</b> .....	81
	<b>BIBLIOGRAFIA</b> .....	83
	<b>ÍNDICE DE FIGURAS</b> .....	87
	<b>ÍNDICE DE TABELAS</b> .....	89
	<b>GLOSSÁRIO</b> .....	91
	<b>ANEXO A: MATRIZES DE CONFUSÃO PARA A CLASSIFICAÇÃO ORIENTADA A OBJETOS, PARA 10 E 14 CLASSES</b> .....	92
	<b>ANEXO B: MATRIZES DE CONFUSÃO PARA A CLASSIFICAÇÃO ORIENTADA A PIXEL, PARA 10 E 14 CLASSES</b> .....	94
	<b>ANEXO C: MATRIZES DE CONFUSÃO PARA A CLASSIFICAÇÃO ORIENTADA A SEGMENTOS, PARA 10 E 14 CLASSES</b> .....	96
	<b>ANEXO D: MATRIZES DE CONFUSÃO PARA A CLASSIFICAÇÃO ORIENTADA A OBJETOS – CARTA DE OCUPAÇÃO DO SOLO DE 2007</b> .....	98
	<b>ANEXO E: MATRIZES DE CONFUSÃO PARA A CLASSIFICAÇÃO ORIENTADA A OBJETOS - CARTA DE OCUPAÇÃO DO SOLO DE 2015</b> .....	99



# 1. Introdução e contextualização

## 1.1 Introdução

A detecção remota é a ciência ou arte que permite adquirir informação de objetos da superfície terrestre, a partir de aviões ou satélites. Essa informação é útil na gestão do território, pois serve como ferramenta de apoio à decisão da administração pública e privada. Campbell e Wynne (2011) consideram a detecção remota como uma ciência que permite a aquisição de informação da superfície terrestre, utilizando imagens obtidas a partir de uma perspectiva aérea, usando a radiação eletromagnética, numa ou mais regiões do espectro eletromagnético, refletida ou emitida a partir da superfície terrestre. Lillesand, Kiefer e Chipman (2004), consideram a detecção remota como uma ciência ou arte de adquirir informações de um objeto, área ou fenómeno, através de análise de dados adquiridos por um dispositivo, não estando em contacto com o objeto, área, ou fenómeno de investigação.

O primeiro requisito para a detecção remota é a existência de uma fonte de energia de modo a iluminar o objeto, essa energia constitui a radiação eletromagnética. Segundo Campbell e Wynne (2011), todos os objetos com uma temperatura superior a zero graus emitem radiação. Ao registar a radiação emitida e refletida e aplicar o conhecimento adquirido sobre o seu comportamento enquanto atravessa a atmosfera e interage com objetos, o analista em detecção remota desenvolve conhecimentos sobre a natureza de elementos, tais como a vegetação, as estruturas, os solos, as rochas, ou corpos de água na superfície da terra. A interpretação de imagens de detecção remota depende assim de uma compreensão profunda da radiação eletromagnética e a sua interação com a superfície e a atmosfera (Campbell e Wynne 2011, p. 6).

Os satélites ou aviões, mais recentemente os UAVs, equipados com sensores, procuram medir com precisão a radiação eletromagnética, irradiada da superfície terrestre e da atmosfera, sendo uma parte fundamental da detecção remota. Segundo Campell (1996), muitas empresas e governos nacionais, operam sistemas de detecção remota, concebidos para a observação da superfície terrestre, com o objetivo de recolher informações relacionadas, com a agricultura, florestas, corpos de água, uso e ocupação do solo, e fenómenos urbanos. Os satélites podem fornecer uma visão sinóptica (observação de

grandes áreas numa única imagem) e uma cobertura sistemática e repetitiva. Estas capacidades são importantes para a criação e manutenção de uma infraestrutura de dados geográficos global e para acompanhar as mudanças em muitas questões ambientais de grande escala que o mundo atualmente enfrenta.

Assim, através das imagens da superfície terrestre recolhidas por intermédio de satélites é possível realizar a sua classificação através de técnicas de processamento digital de imagem, agrupando pixéis semelhantes, representando, classes de ocupação do solo, podendo ser floresta, tecido urbano, agricultura, corpos de água e outros tipos. Existem três tipos de processamento digital de imagem: classificação supervisionada, classificação não supervisionada e classificação orientada a objetos. Segundo Campbell e Wynne (2011), a classificação digital de imagens é o processo de atribuir pixéis a classes. Normalmente, cada pixel é considerado como uma unidade individual constituída por valores em várias bandas espectrais. Ao comparar os pixéis entre si e pixéis de identidade conhecida, é possível reunir grupos de pixéis semelhantes em classes associadas com categorias de informação de interesse, para utilizadores de dados de deteção remota. Estas classes formam regiões num mapa ou numa imagem, de tal forma que a classificação da imagem digital é apresentada como um mosaico de parcelas uniformes, cada uma identificada por um cor ou um símbolo.

A presente dissertação tem por objetivo geral a classificação de dados Landsat 8 do norte de Portugal com recurso a Geographic Object-Based Image Analysis (GEOBIA). Noutra perspetiva, o verdadeiro desafio é o de utilizar a abordagem orientada a objetos em dados muito recentes de média resolução espacial e espectral, como é o caso dos dados Landsat 8, visto que a principal aplicação da abordagem orientada a objetos é em imagem de alta resolução espectral e, sobretudo, espacial.

Esta dissertação compreende cinco capítulos, onde se expõe a relevância e o uso da abordagem GEOBIA para a classificação de imagens de média resolução espectral e espacial

O primeiro capítulo da presente dissertação tem por base a contextualização teórica, onde se realiza uma descrição dos vários processos clássicos de classificação de dados



obtidos por detecção remota, como por exemplo, a abordagem pixel a pixel (classificadores supervisionados e não supervisionados), a abordagem orientada a segmentos e objetos.

No segundo capítulo, discute-se se o GEOBIA é um novo paradigma ou um novo conceito.

O terceiro capítulo aborda a metodologia adotada na presente dissertação. É selecionada a área de estudo, que no âmbito desta tese recai sobre a região norte de Portugal, devido à sua elevada heterogeneidade, que permite um estudo mais diversificado. Os dados escolhidos foram o Landsat 8, por ser o satélite de imagens de baixa resolução espectral e espacial mais recente, sendo a imagem trabalhada datada de 9 de Julho de 2014. A nomenclatura utilizada na classificação, ou seja, que vai funcionar como a realidade do terreno, é o nível 2 da carta de uso e ocupação do solo de Portugal Continental para 2007 (COS2007). Antes de se iniciar a extração de elementos e classificação de imagem orientada a objetos, procedeu-se ao processo de fusão de imagem, de modo a melhorar a resolução espacial das bandas multiespectrais. Após a fusão de imagem, procedeu-se à extração de elementos e classificação de imagem orientada a objetos, onde o *software* utilizado foi o *eCognition*, utilizou-se a extração de elementos a partir de regras de classificação e o algoritmo vizinho mais próximo.

No quarto capítulo ilustra-se os diferentes resultados, obtidos das diferentes abordagens de classificação de imagem.

Já no quinto e último capítulo, faz-se a discussão de resultados, recorrendo à apresentação de imagens comparando o resultado da classificação de imagem com a COS2007, e no qual se procede à discussão dos resultados através da matriz de confusão, o índice de concordância *Kappa*, erro de comissão e omissão, exatidão do utilizador e produtor.

## 1.2 Objetivos

A presente dissertação tem como principal objetivo a classificação de dados *Landsat 8* para o Norte de Portugal com recurso a *Geographic Object-Based Image Analysis* (GEOBIA).

Será utilizada uma nova subdisciplina das ciências de informação geográfica, a GEOBIA, proposta por Hay e Castilla, (2006), com o propósito de se diferenciar de outras disciplinas. Hay e Castilla (2006) referem que a GEOBIA é uma subdisciplina das ciências de Informação Geográfica, dedicada ao desenvolvimento de métodos automatizados de segmentação de imagens de deteção remota em objetos, servindo para avaliar as suas características através de escalas espaciais, espectrais e temporais, de modo a gerar nova informação geográfica em formato matricial e vetorial.

Mais especificamente, a presente dissertação terá como objetivo desenvolver cartografia de ocupação do solo para o norte de Portugal, através da classificação orientada a objetos, que vem ganhando espaço no mundo das ciências geográficas, em relação a outros métodos e técnicas. Nesta dissertação procura-se explorar as potencialidades desta nova abordagem para dados recentes, como é o caso das imagens de satélite *Landsat 8*, comparando a sua exatidão com os outros tipos de classificadores (pixel a pixel e orientada a segmentos). Posteriormente irá ser calculada a exatidão global, do produtor e do utilizador utilizando como dados de referência a cartografia da carta de ocupação do sol de 2007 (COS 2007).

### 1.3 Estrutura da tese

A presente dissertação está dividida em cinco capítulos, eles são:

O primeiro capítulo trata a contextualização teórica, ou seja, explica os processos clássicos de classificação de dados obtidos por detecção remota, eles são, a abordagem pixel a pixel, através dos classificadores supervisionados e não supervisionados; a abordagem orientada a segmentos; e a abordagem orientada a objetos.

O segundo capítulo procede-se à apresentação do tema desta dissertação e a sua importância do presente estudo.

No terceiro capítulo, referente à metodologia, procede-se à apresentação da área de estudo que irá ser trabalhada nesta dissertação, as características dos dados *Landsat 8* a ser utilizados, a nomenclatura de classificação que irá ser utilizada para a conceção dos resultados finais, o fluxograma de procedimentos efetuados nos *software* de processamento digital de imagem. Posteriormente, procede-se à apresentação das ferramentas presentes no *software eCognition*. Por último, explica-se os cálculos para a avaliação de exatidão temática, sendo eles a matriz de confusão, exatidão global, índice de concordância *Kappa*, erro de comissão, omissão, exatidão do utilizador e produtor.

No quarto capítulo apresenta-se os resultados obtidos pelos diferentes classificadores.

Por último, o quinto capítulo são analisados os resultados obtidos a partir dos diferentes classificadores. Por forma a avaliar os resultados e o desempenho dos diferentes classificadores, foi realizada uma análise de concordância entre os resultados obtidos e a realidade do terreno representada pela carta de ocupação do solo de 2007, para tal foi produzida cartografia, cálculos e tabelas das respetivas classes de ocupação do solo.

Os procedimentos efetuados foram desenvolvidos no *software* de processamento digital de imagem – *eCognition* 9.0. A figura 1 resume os procedimentos realizados.

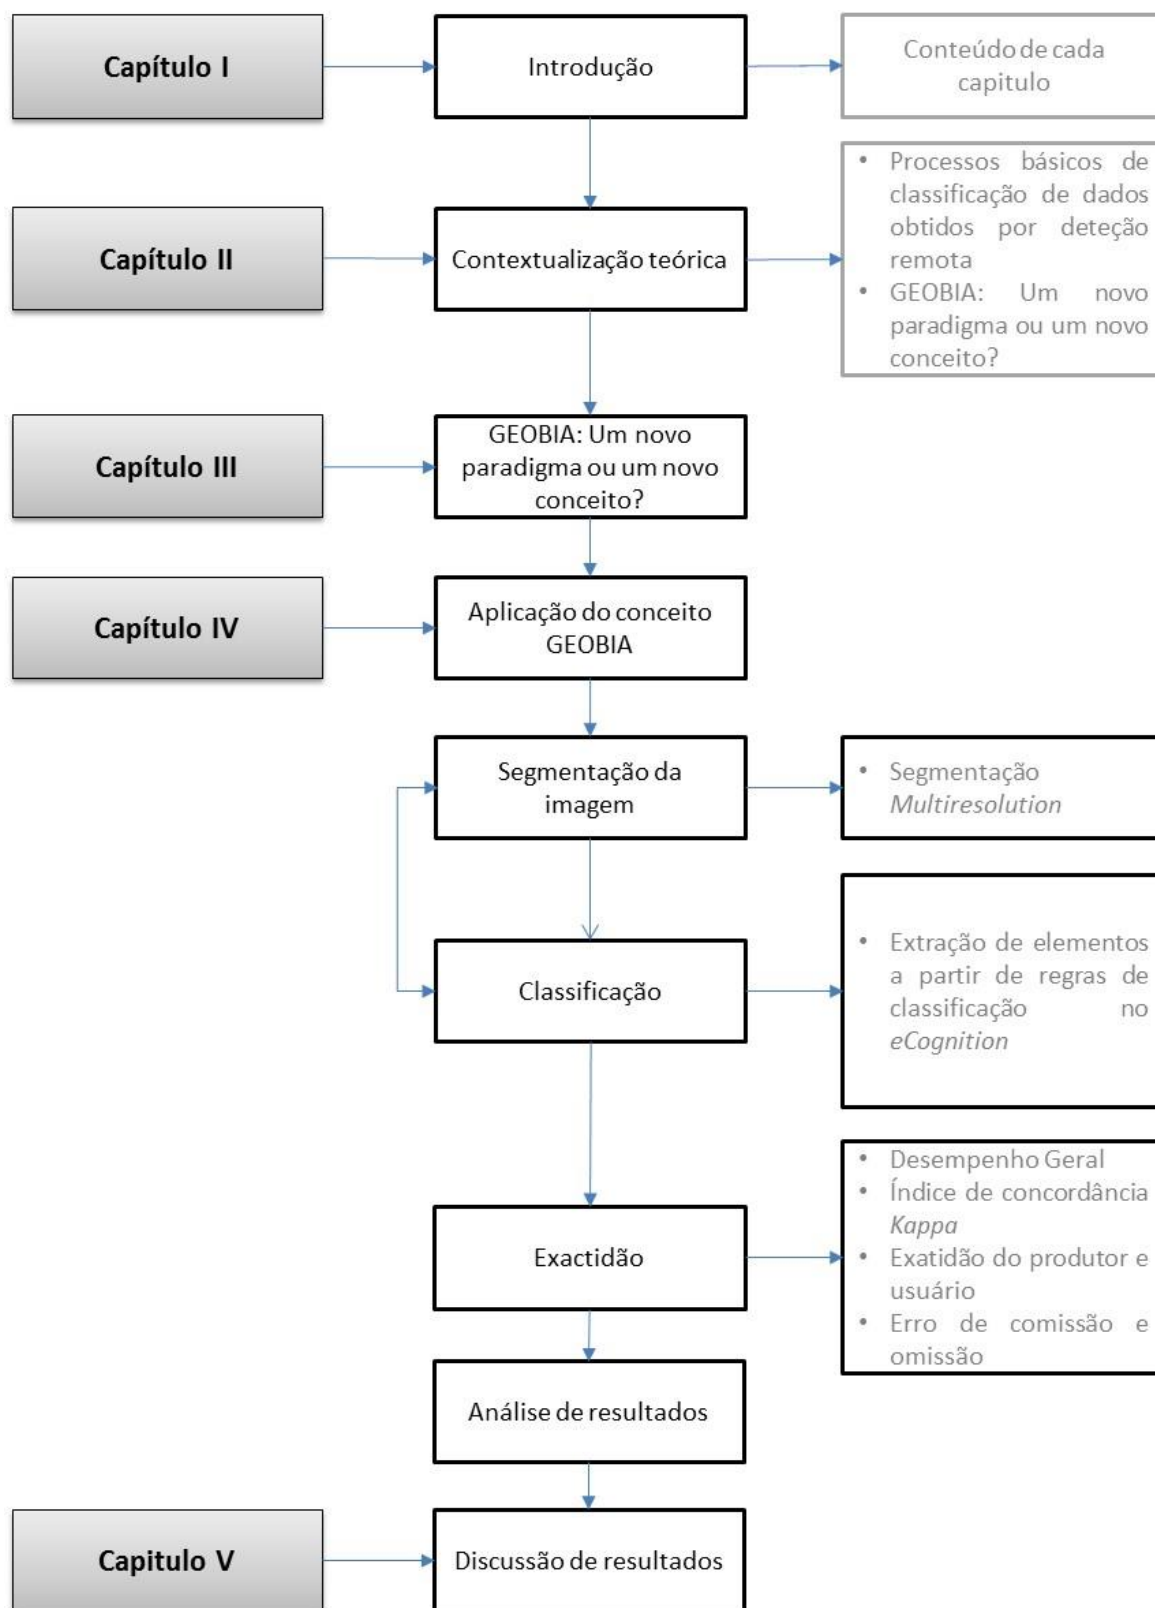


Figura 1: Estrutura da dissertação e fluxograma geral de procedimentos.

## 2. Capítulo II: Contextualização teórica

### 2.1 Processos clássicos de classificação de dados obtidos por detecção remota

#### 2.1.1 Abordagem pixel a pixel

##### 2.1.1.1 Classificadores supervisionados

A classificação supervisionada é o procedimento utilizado com maior frequência para análise quantitativa de dados de imagens de detecção remota. Neste processo são utilizados algoritmos para designar os pixels em uma imagem, de forma a representar tipos específicos de cobertura terrestre, ou classes que são conhecidas *a priori* (LILLESAND, KIEFER, 1994). Na classificação supervisionada o utilizador tem um conhecimento prévio da área geográfica. Ele identifica e categoriza regiões de interesse na imagem, de acordo com as suas assinaturas espectrais. Em seguida realiza-se a classificação da imagem, onde o *software* agrupa os pixels de acordo com a sua refletância espectral.

Já Campbell e Randolph (2011) referem que a classificação supervisionada pode ser definida como o processo de utilização de amostras de identidade conhecida (pixels atribuídos a categorias informativas) para classificar pixels de identidade desconhecida (ou seja, para atribuir pixels não classificados a uma de várias categorias informativas). As amostras de identidade conhecida consistem nos pixels localizados em áreas de formação ou campos de formação. O analista define as áreas de formação através da identificação de regiões na imagem que só podem ser claramente combinadas com as áreas de identidade na imagem. Estas áreas devem tipificar propriedades espectrais das categorias que representam e devem ser homogêneas no que diz respeito à categoria informativa a ser classificada. Ou seja, as áreas de formação não devem incluir regiões heterogêneas, nem devem abranger fronteiras entre as categorias. O tamanho, a formação e a posição devem favorecer uma identificação adequada, tanto na imagem como no terreno. Os pixels localizados dentro dessas áreas formam as amostras de formação utilizadas para indicar o algoritmo de classificação para atribuir valores espectrais específicos de modo a apropriar-se de categorias informativas. Claramente, a seleção de dados de formação é um passo chave na classificação supervisionada.

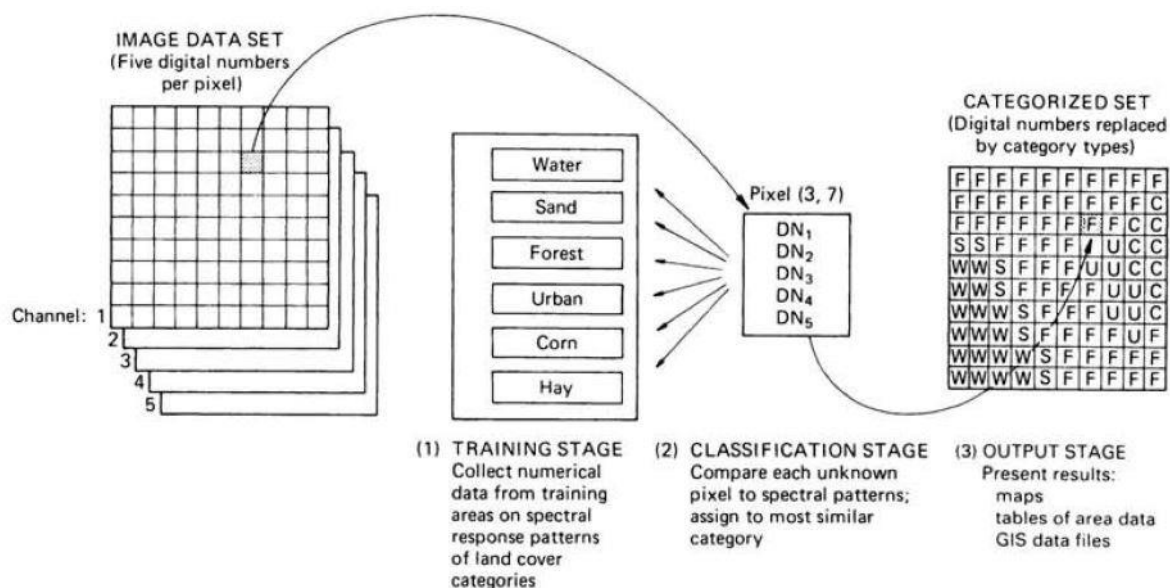


Figura 2: Processos básicos da classificação supervisionada. Fonte: Lillesand, T. and Kiefer, R. (2000).

### 2.1.1.2 Classificadores não-supervisionados

Os classificadores não-supervisionados não utilizam dados de treino como base para a sua classificação. Em vez disso, estes classificadores envolvem algoritmos que examinam os pixels numa imagem desconhecida e agregam-nos em várias classes, com base em agrupamentos naturais ou agregados com base nos valores espectrais da imagem. A sua premissa básica é que os valores de um determinado tipo de solo devem estar próximos, enquanto os valores de classes diferentes devem ser separados (LILLESAND, KIEFER, 1994, p. 573). No fim desta abordagem, o utilizador procura fazer a correspondência entre uma classe espectral a uma classe temática. Os classificadores não-supervisionados mais conhecidos são o *K-means* e o *Isodata*.

O *K-means* é implementado através da migração recursiva de um conjunto de meios de agrupamento (centros), que utilizam a distância mais próxima até que as localizações dos meios de agrupamento sejam inalterados ou até que a mudança de uma iteração para a próxima seja inferior a um limiar predefinido. A mudança pode também ser definida em termos do número de pixels que se deslocam de um meio de agrupamento para outro entre iterações, ou pelo valor de uma medida de compacidade de um meio de agrupamento, tal como a soma dos quadrados dos desvios de cada pixel do centro do seu agrupamento, somado por todas as classes (TSO, MATHER 2009).

Já o *Isodata* permite que o número de agrupamentos altere de uma iteração para a próxima, através da fusão, cisão e exclusão de agrupamentos. De um modo geral o processo

é semelhante ao descrito para o *K-means*. No entanto, em cada iteração, as estatísticas que descrevem cada agrupamento são avaliadas de acordo com a atribuição de pixels para cada um deles. Se a distância entre os pontos médios dos dois grupos é inferior a uma distância mínima predefinida, os dois conjuntos são unidos em conjunto. Por um lado, se um único conjunto tem um desvio padrão (em qualquer dimensão) maior do que um valor máximo predefinido, o conjunto é dividido em dois. Agrupamentos com menos do que um número mínimo especificado de pixels são excluídos. Finalmente, à semelhança dos *K-means*, todos os pixels são reclassificados para o conjunto revisto de agrupamentos e o processo repete-se até que não exista nenhuma mudança significativa nas estatísticas do agrupamento ou o número máxima de iterações seja alcançado (LILLESAND et al. 2004).

### 2.1.2 Abordagem orientada a segmentos

Os algoritmos de classificação orientada a segmentos não utilizam dados de treino como base para a classificação. Os pixels são examinados e agregados em classes com base nos agrupamentos naturais presentes nos valores da imagem. A premissa básica é que os valores correspondentes a um certo tipo de cobertura encontram-se próximos, enquanto valores de diferentes classes devem estar comparativamente bem separados no espaço de atributos da imagem (LILLESAND et al. 2004).

Já Eastman (2009) refere que a classificação orientada por segmentos, agrupa os pixels adjacentes da imagem em segmentos de acordo com a sua similaridade espectral, sendo que a circunscrição da imagem em ‘objetos’ é efetuada com base na variância dos dados digitais da imagem.

O *software eCognition* possibilita a segmentação e classificação dos objetos da imagem, este processo irá ter várias tentativas até encontrar-se os valores de segmentação adequados, que variam entre 0 e 100. Terminado a fase da segmentação, procede-se para a atribuição de cada segmento, a uma classe de ocupação do solo da nomenclatura carta de ocupação do solo de 2007. Após a fase de atribuição de classes, vai utilizar-se o algoritmo vizinho mais próximo no *eCognition*.

### 2.1.3 Abordagem orientada a objetos

Desenvolvimentos recentes na detecção remota tornaram possível obter dados de uma resolução espacial muito elevada que permite a extração, avaliação e monitorização de uma vasta gama de possíveis recursos de destino. Paralelamente, a demanda para automatizar a análise de imagens em ambientes operacionais está constantemente a crescer. No entanto, a variedade e número de diferentes características a serem extraídas, acrescentou vários desafios, especialmente em termos de modelagem e procedimentos auto adaptativos. A vantagem de uma resolução espacial de pixéis com tamanhos significativamente menores do que o tamanho médio do objeto de interesse traz a desvantagem de uma elevada quantidade de detalhe espacial, e consequentemente, uma enorme quantidade de dados a serem processados. Para superar esta desvantagem, a abordagem de análise de imagem baseada em objetos provou ser uma alternativa à análise de imagem baseada em pixéis e um grande número de publicações sugerem que melhores resultados podem ser aguardados (BAATZ et al. 2008, p 29)

Segundo Hay e Castilla (2008), a abordagem orientada a objetos possui vantagens em relação aos modelos tradicionais de classificação de imagens: pelo fato de os elementos considerados não serem os pixéis isolados, mas grupos deles (regiões de pixéis), obtém-se um significativo aumento no número de variáveis consideradas na classificação, pois além das informações espectrais, torna-se possível descrever cada região usando parâmetros em relação à forma do objeto (área, altura, largura, densidade, altura da borda, entre outros), à textura, às relações entre objetos vizinhos, entre outros.

Já Campbell e Randolph (2011), consideram que a classificação orientada por objetos utiliza um processo dividido em duas etapas que se destina a simular os processos de classificação de ordem superior, cada um composto por diversos processos intermediários. A classificação orientada por objetos aplica uma lógica que se destina a imitar algumas das maiores lógicas de ordem superior aplicadas por intérpretes humanos, que podem utilizar os tamanhos, formas e texturas de regiões, bem como as características espectrais utilizadas para a classificação com base em pixéis convencionais.

É na classificação orientada a objetos que se vai fazer uma análise mais aprofundada e exploratória, para o caso vai ser utilizado o *software eCognition*. O primeiro passo na orientação a objetos vai ser a realização da segmentação da imagem, em objetos, de acordo com a sua área, altura, largura, densidade, textura. No *eCognition*, para a segmentação de



imagens irá utilizar-se o processo de multiresolução, onde se aplica um valor no parâmetro da segmentação, de modo a encontrar um valor ideal. Após terminada a fase da segmentação, atribui-se uma classe de ocupação do solo da nomenclatura da carta de ocupação do solo de 2007, executando-se o classificador.

### 3. Capítulo III: Geographic object based image analysis (GEOBIA): Um novo paradigma ou um novo conceito?

Para entender como ocorre a mudança de paradigma na interpretação de imagens satélite de detecção remota, é preciso entender o conceito de paradigma. Esse conceito surge através de Thomas Khun, na sua obra *A Estrutura das Revoluções Científicas* (1962), em que defende que os grandes progressos da ciência não resultam de mecanismos de continuidade, mas sim de mecanismos de rutura. A certa altura, alguns dos praticantes dessa ciência descobriram contradições internas chegando à conclusão de que a forma de ver o mundo por parte dessa ciência não é adequada. Constando assim que o mundo deveria ser visto de forma diferente. Às diversas formas de ver o mundo, Kuhn chamou paradigmas. Quando alguém descobre um paradigma distinto, sobre o qual é possível basear o desenvolvimento de uma ciência, diz-se que a ciência é, durante esse período, uma Ciência Revolucionária<sup>1</sup>.

Através do esclarecimento do conceito de paradigma pode-se entender, porque alguns autores consideram, a mudança de uma abordagem pixel a pixel, tradicional, para uma abordagem orientada a objetos. Hay e Castilla (2006), consideram que é uma mudança de paradigma relativamente recente na análise de imagens de detecção remota, tem vindo a ocorrer nas últimas duas décadas, que promete mudar a nossa forma de pensar, analisar e utilizar as imagens de detecção remota. Com o surgimento deste novo paradigma, os utilizadores terão mudado de um modelo predominantemente baseado em análise espectral ao pixel, para um modelo dinâmico baseado na análise dos objetos, que tenta reproduzir a maneira como o cérebro humano interpreta as imagens. No entanto, ao longo desse novo caminho, de pixéis para objetos, a inteligência e a consolidação desse novo paradigma, ainda existem inúmeros desafios a serem abordados.

“*Geographic object base image analysis* (GEOBIA) é uma subdisciplina das ciências de Informação Geográfica, dedicada ao desenvolvimento de métodos automatizados de segmentação de imagens de detecção remota em objetos, servindo para avaliar as suas

---

<sup>1</sup> Noção de Paradigma. Thomas Kuhn. Disponível em [http://filosofia.projectos.esfll.pt/T\\_Khun/Paradigmas\\_Khun.pdf](http://filosofia.projectos.esfll.pt/T_Khun/Paradigmas_Khun.pdf). Acesso em 17 de Janeiro de 2015.

características através de escalas espaciais, espectrais e temporais, de modo a gerar nova informação geográfica em formato matricial e vetorial (Hay e Castilla 2006, p.77).

Já Blaschke (2013) interroga-se, apesar do grande aumento ao longo dos anos do número de publicações científicas, estas não vem suportando a ideia que GEOBIA seja um novo paradigma.

O termo GEOBIA foi criado por Hay e Castilla (2006) para se diferenciar de outras áreas científicas, que compartilhavam o termo OBIA. Os conceitos e potencialidades do GEOBIA foram reconhecidos durante a década de 80, porém, não existia capacidade computacional para aplicar análises orientadas a objeto e à falta de imagens de alta resolução espectral (Aplin e Smith, 2011). Com o avanço na capacidade computacional, armazenamento de dados e o aparecimento das primeiras imagens satélite de alta resolução espectral, no final dos anos 90, início de 2000, resolve-se os problemas de processamento digital de imagens (Blaschke, 2010). No ano 2000, coincidentemente com o advento dos satélites comerciais de alta resolução espacial, um *software*, chamado eCognition, obtendo um grande sucesso no mercado. Outros produtos se seguiriam, de empresas já estabelecidas no mercado e por novas empresas (Blaschke 2013).

GEOBIA veio opor-se ao método tradicional de classificação de imagens, a abordagem a pixéis, que apresenta limitações nas imagens de alta resolução espacial, apesar de essa abordagem apresentar melhores desempenhos nas imagens de baixa resolução espacial. Mas com o aumento de qualidade das imagens multiespectrais, a abordagem a pixéis, já vem encontrando limitações. A escala é um conceito importante em GEOBIA para a análise da imagem, razão pelo qual a orientação a objetos, só se concretizou com o aparecimento de imagens de alta resolução espacial. A resolução das imagens tem de ser alta o suficiente, para que a análise dos objetos, os objetos do mundo real sejam analisados a uma “escala focal” (Blaschke 2010, p. 3)

Burnett e Blaschke (2003) explicam que a principal diferença entre a abordagem GEOBIA e a pixéis é que a escala de análise é diferente. Nos métodos a pixéis, a análise é realizada a células individuais, ou pixéis, formando uma matriz arbitrária e abstrata sobre a imagem e não tem correlação direta com os objetos do mundo real. Em uma análise orientada a objetos, o processo de segmentação de uma imagem processa grupos de pixéis

em regiões homogêneas e heterogêneas “objetos de imagem”, que correspondem aos objetos do mundo real (Blaschke e Strobl 2001). Outra falha com os métodos orientados a *pixel*, é que uma parte substancial do sinal espectral vindo da terra de um pixel, vem dos pixels adjacentes (Blaschke e Strobl 2001).

## 4. Capítulo IV: Metodologia e resultados

### 4.1 Área de estudo

A área de estudo corresponde à região norte de Portugal, integrando 83 concelhos, ocupando uma área total de 22615 km<sup>2</sup>, limitada a norte por Espanha e a oeste pelo oceano Atlântico.

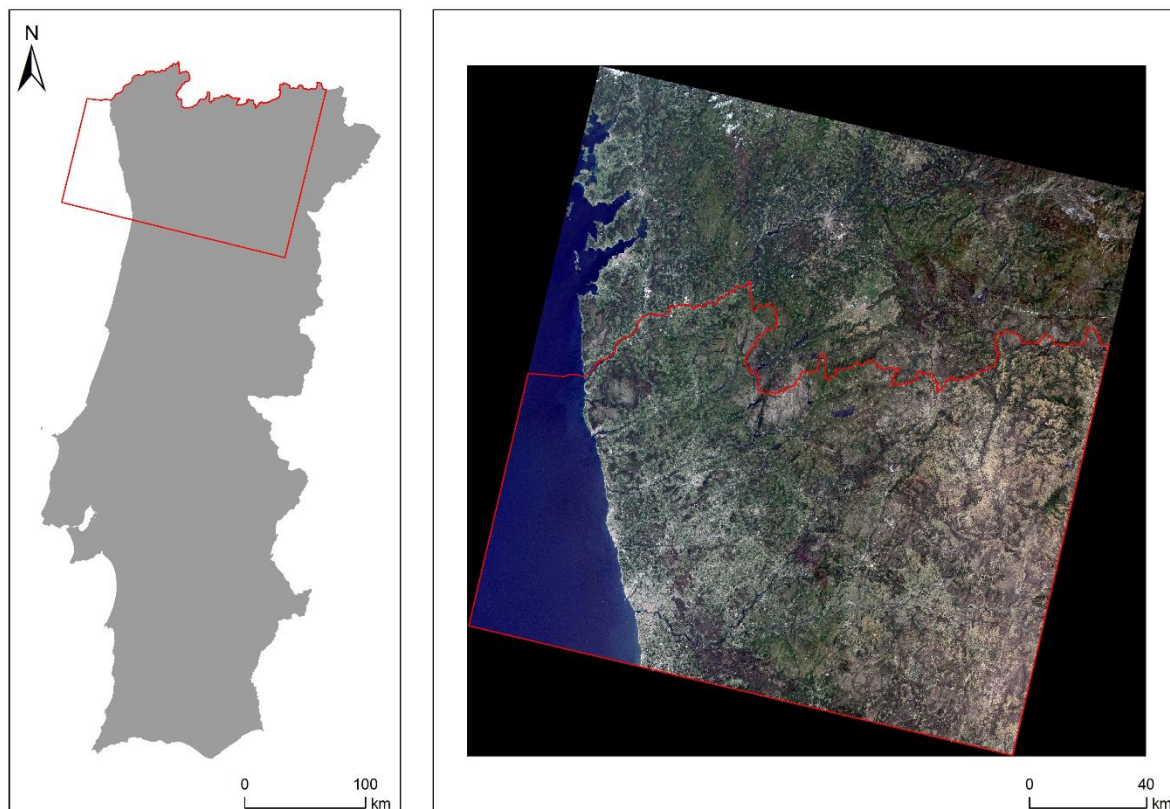


Figura 3: Enquadramento da área de estudo.

A imagem satélite é caracterizada por uma grande variabilidade espectral, resultante da grande diversidade de ocupação do solo, devido a ocupar uma larga extensão geográfica. Os territórios artificializados predominam na área litoral da imagem, enquanto no interior predominam as classes de áreas agrícolas e agro-florestais e florestas e meios naturais e semi-naturais.

## 4.2 Dados

Para o projeto foram descarregadas imagens *Landsat 8 OLI/TIRS*, a partir da plataforma em *open access data EarthExplorer*<sup>2</sup>. A tabela 1 resume as características das imagens a ser utilizadas na dissertação.

Processamento Digital de Imagem		
Satélite	Landsat 8	
Sensor	OLI/TIRS	
Data de lançamento	30 de Maio de 2013	
Formato da imagem	GeoTIFF (raster)	
Localização	Row: 204 Path: 31	
Datum de referência de origem	WGS84	
Projeção	UTM Zona 29N X1 = 470385.0 X2 = 701715.0	
Coordenadas	Y1 = 4740615.0 Y2 = 4505385.0	
Data de aquisição	09-07-2014	
Inclinação	98,2	
Altitude	705 Km	
Produtor dos dados	USGS	
Nível de correção geométrica	Ortho	
Resolução temporal	16 Dias	
Resolução radiométrica	12 Bits	
Resolução espectral	11 Bandas	
Banda	Largura de banda ( $\mu\text{m}$ )	Resolução espacial
B1	Costal Aerosol (0.43 a 0.45 $\mu\text{m}$ )	30
B2	Azul (0.45 a 0.51 $\mu\text{m}$ )	
B3	Verde (0.53 a 0.59 $\mu\text{m}$ )	
B4	Vermelho (0.64 a 0.67 $\mu\text{m}$ )	
B5	Infravermelho proximo (0,85 a 0,88 $\mu\text{m}$ )	
B6	Infravermelho médio 1 (1.57 1.65 $\mu\text{m}$ )	15
B7	Infravermelho médio 2 (2.11 2.29 $\mu\text{m}$ )	
B8	Pancromático (0.50 0.68 $\mu\text{m}$ )	
B9	Cirrus (1.36 - 1.38 $\mu\text{m}$ )	
B10	Infravermelho térmico (TIRS) 1 (10,60 a 11,19 $\mu\text{m}$ )	
B11	Infravermelho térmico (TIRS) 2 (11,50 a 12,51 $\mu\text{m}$ )	30
País	Portugal	
Área de estudo	Região norte de Portugal Continental	

Tabela 1: Características do satélite *Landsat 8*.

<sup>2</sup> <http://earthexplorer.usgs.gov/> (2014)

#### 4.2.1 Características do satélite Landsat 8

O satélite *Landsat 8* foi lançado em 30 de Maio de 2013 e é o oitavo satélite do programa *Landsat*.

As principais novidades do satélite *Landsat 8* em relação aos seus antecessores são a introdução de dois novos sensores. O **Operational Land Imager** (OLI) que apresenta semelhanças com o sensor ETM+ do *Landsat 7*, mas apresenta duas novas bandas espectrais, a banda 1 do *coastal aerosol* e a banda 9 do cirros. O **Thermal Infrared Sensor** (TIRS), que acrescenta mais uma banda do infravermelho térmico em comparação com os seus antecessores, passando dos 60 metros de resolução espacial dos anteriores satélites Landsat para 30 metros (figura 4).





Figura 4: Comparação dos comprimentos de onda entre o Landsat 8 e 7. Fonte: [http://landsat.usgs.gov/L8\\_band\\_combos.php](http://landsat.usgs.gov/L8_band_combos.php).


### Sensor *Operational Land Imager* (OLI)

---


A banda 1 do *coastal aerosol* (0.43 a 0.45  $\mu\text{m}$ ), permite o estudo de áreas costeiras, como por exemplo averiguar a qualidade da água em águas costeiras e interiores e a detecção de aerossóis na atmosfera.



A banda 2 da região do visível corresponde ao azul (0.45 a 0.51  $\mu\text{m}$ ). Esta banda serve para distinguir o solo da vegetação e também para distinguir a vegetação decídua e conífera.




A banda 3 da região do visível corresponde ao verde (0.53 a 0.59  $\mu\text{m}$ ).







A banda 4 da região do visível corresponde ao vermelho ( $0.64 - 0.67 \mu\text{m}$ )





A banda 5 corresponde ao infravermelho próximo ( $0,85$  a  $0,88 \mu\text{m}$ ). Esta banda é especialmente importante para realçar a biomassa de um sistema e diferenciar a vegetação saudável da não saudável através do cálculo do NDVI. Também serve para definir as linhas costeiras, já que os corpos possuem um baixo nível espectral nesta banda.




A banda 6 e 7 correspondem ao infravermelho médio 1 ( $1.57 - 1.65 \mu\text{m}$ ) e 2 ( $2.11 - 2.29 \mu\text{m}$ ). Estas duas bandas do espectro são utilizadas para diferenciar solos secos de húmidos e para a geologia, já que permite separar espectralmente rochas e solos devido a terem um forte contraste nesta banda.



A banda 8 corresponde à banda pancromática (0.50 0.68  $\mu\text{m}$ ) e é a banda com melhor resolução espacial do satélite Landsat 8 com 15 metros. Através do método *pan sharpening* é possível combinar esta banda com as restantes, com o objetivo de melhorar a resolução geométrica.



A banda 9 é a principal novidade e corresponde à banda cirros (1.36 - 1.38  $\mu\text{m}$ ). Permite a deteção de nuvens cirros de alta altitude, as nuvens surgem brilhantes enquanto a superfície terrestre surge a escuro.





---

*Thermal Infrared Sensor (TIRS)*

---

---

O sensor TIRS, contém as duas bandas, o infravermelho-térmico 1 (10,60 a 11,19  $\mu\text{m}$ ) e o infravermelho-térmico 2 (11,50 a 12,51  $\mu\text{m}$ ), ambas permitem medir a temperatura e a humidade da superfície terrestre.



---

Tabela 2: Caraterísticas das bandas Landsat 8.

### 4.3 Nomenclatura

Segundo Congalton e Green (1999), a primeira decisão na recolha de dados é determinar quais os dados a ser utilizados como dados de referência. O tipo de dados dependerá da complexidade do esquema da classificação. Por vezes, mapas ou dados do terreno servem como dados de referência. Os dados de referência precisam de ser mais rigorosos que os dados adquiridos por deteção remota e pelos métodos utilizados para realizar a classificação. Ortofotomapas são muitas vezes utilizados para avaliar a exatidão global dos mapas feitos a partir de imagens de satélite. Visitas ao terreno e a interpretação visual da imagem são muitas vezes utilizadas para avaliar a exatidão global das classificações criadas a partir de imagens de alta e baixa resolução espectral

Antes de iniciar o processamento digital de imagem, obtém-se a carta administrativa oficial de Portugal (CAOP), utilizando a mesma, como uma máscara de modo a delimitar a área de estudo para a imagem *Landsat* 8.

A nomenclatura de ocupação do solo utilizada nesta dissertação é a da carta de uso e ocupação do solo de Portugal Continental para 2007 (COS2007).

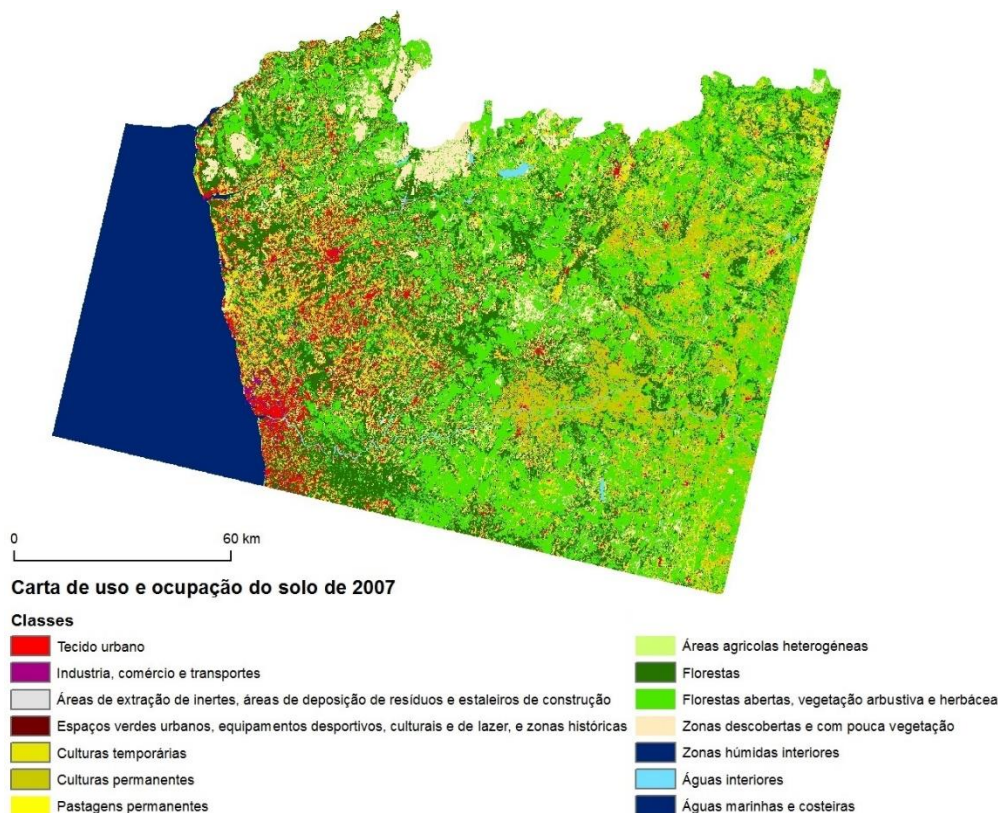


Figura 5: Carta de uso e ocupação do solo de Portugal Continental para 2007.

*A COS2007 é uma cartografia temática que pretende caracterizar com grande detalhe a ocupação/uso do solo no território de Portugal Continental. Com o projeto COS2007 pretendeu-se atualizar a edição anterior (de 1990) da Carta de Ocupação do Solo (COS'90), introduzindo-se no entanto uma série de alterações significativas, que a nível das metodologias e regras de produção cartográfica, quer a nível da nomenclatura utilizada. Na nova edição destaca-se ainda o esforço de harmonização com normas e práticas internacionais, de que são exemplo a utilização do sistema de referência ETRS89 ou a compatibilização da nomenclatura da COS2007 com a nomenclatura CORINE Land Cover, este último um produto de referência em ocupação/uso do solo na Europa e em Portugal.*<sup>3</sup>

Nível 1	Nível 2	Nível 3
1 Territórios artificializados	1.1 Tecido urbano	1.1.1 Tecido urbano contínuo 1.1.2 Tecido urbano descontínuo
	1.2 Indústria, comércio e transportes	1.2.1 Indústria, comércio e equipamentos gerais 1.2.2 Redes viárias e ferroviárias e espaços associados 1.2.3 Áreas portuárias 1.2.4 Aeroportos e aeródromos
	1.3 Áreas de extração de inertes, áreas de deposição de resíduos e estaleiros de construção	1.3.1 Áreas de extração de inertes 1.3.2 Áreas de deposição de resíduos 1.3.3 Áreas em construção
	1.4 Espaços verdes urbanos, equipamentos desportivos, culturais e de lazer, e zonas históricas	1.4.1 Espaços verdes urbanos 1.4.2 Equipamentos desportivos, culturais e de lazer e zonas históricas
2 Áreas agrícolas e agro-florestais	2.1 Culturas temporárias	2.1.1 Culturas temporárias de sequeiro 2.1.2 Culturas temporárias de regadio 2.1.3 Arrozais
	2.2 Culturas permanentes	2.2.1 Vinhas 2.2.2 Pomares 2.2.3 Olivais
	2.3 Pastagens permanentes	2.3.1 Pastagens permanentes
	2.4 Áreas agrícolas heterogéneas	2.4.1 Culturas temporárias e/ou pastagens associadas a culturas permanentes 2.4.2 Sistemas culturais e parcelares complexos 2.4.3 Agricultura com espaços naturais e semi-

<sup>3</sup> Carta de Uso e Ocupação do solo de Portugal Continental para 2007 (COS2007) – Memória Descritiva.

		naturais 2.4.4 Sistemas agro-florestais
3 Florestas e meios naturais e seminaturais	3.1 Florestas	3.1.1 Florestas de folhosas 3.1.2 Florestas de resinosas 3.1.3 Florestas mistas
	3.2 Florestas abertas, vegetação arbustiva e herbácea	3.2.1 Vegetação herbácea natural 3.2.2 Matos 3.2.3 Vegetação esclerófila 3.2.4 Florestas abertas, cortes e novas plantações
	3.3 Zonas descobertas e com pouca vegetação	3.3.1 Praias, dunas e areais 3.3.2 Rocha nua 3.3.3 Vegetação esparsa 3.3.4 Áreas áridas 3.3.5 Neves eternas e glaciares
4 Zonas húmidas	4.1 Zonas húmidas interiores	4.1.1 Paúis 4.1.2 Turfeiras
	4.2 Zonas húmidas litorais	4.2.1 Sapais 4.2.2 Salinas e aquicultura litoral 4.2.3 Zonas entre-marés
5 Corpos de água	5.1 Águas interiores	5.1.1 Cursos de água 5.1.2 Planos de água
	5.2 Águas marinhas e costeiras	5.2.1 Lagoas costeiras 5.2.2 Desembocaduras fluviais 5.2.3 Oceano

Tabela 3: Nomenclatura da carta de uso e ocupação do solo de Portugal continental para 2007.

*A COS2007 foi produzida com base na interpretação visual de imagens aéreas ortorrectificadas, de grande resolução espacial (50 cm) e quatro bandas espectrais (azul, verde, vermelho e infra-vermelho próximo). No processo de produção, bem como no controlo de qualidade, fez-se uso de bases de dados auxiliares provenientes de fontes diversas, incluindo séries multi-temporais intra-anuais de imagens de satélite.*

Carta de Uso e Ocupação do Solo de Portugal Continental para 2007

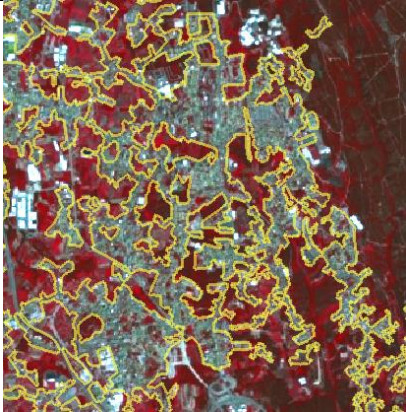



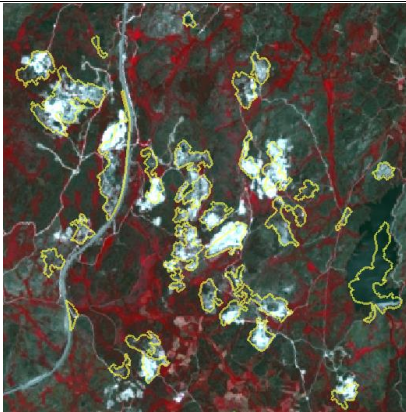
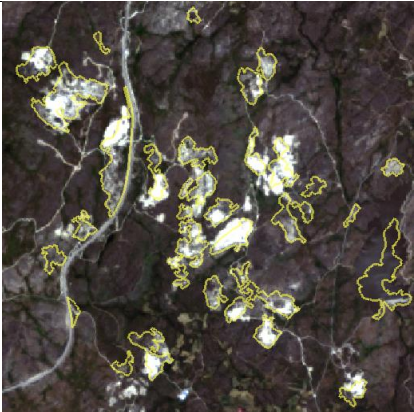
Modelo de dados	Vetorial
Estrutura dos dados	Polígonos
Unidade mínima cartográfica (UMC)	1 há
Distância mínima entre linhas	20 m
Largura mínima de polígonos	20 m
Sistema de georreferência	ETRS89/PT-TM06
Sistema de coordenadas	
Elipsóide	GRS80
Projeção	Transversa de Mercator
Origem das coordenadas retangulares - Latitude	39° 40' 05", 73 N
Origem das coordenadas retangulares – Longitude	08° 07' 59", 19 W
Falsa origem das coordenadas retangulares	$\Delta X = 0$ m
	$\Delta Y = 0$ m
Fator de escala do meridiano central	K = 1
Nomenclatura	
Nomenclatura	Nomenclatura hierárquica com cinco níveis de detalhe e 193 classes no 5º nível
Dados de base	Imagens aéreas ortorrectificadas
Referência de delimitação administrativa	Carta Administrativa Oficial de Portugal (CAOP), versão 2008.1

Tabela 4: Características da carta de uso e ocupação do solo de Portugal continental para 2007.



Ao escolher a nomenclatura, decidiu-se pela utilização do nível 2, que é composta pelas seguintes classes de ocupação do solo:

Classe da carta de uso e ocupação do solo de Portugal Continental para 2007

Classes nível 2	Combinação falsa cor 5/4/3	Combinação colorida 4/3/2
Tecido urbano		
Indústria, comércio e transportes		
Áreas de extração de inertes, áreas de deposição de resíduos e estaleiros de construção		




---


Espaços verdes urbanos,  
equipamentos desportivos,  
culturais e de lazer, e zonas  
históricas





Culturas temporárias



Culturas permanentes




Pastagens permanentes









Áreas agrícolas heterogêneas





Florestas




Florestas abertas e vegetação arbustiva e herbácea




Zonas descobertas e com pouca vegetação



Zonas húmidas litorais



Águas interiores



Águas marinhas e costeiras





Tabela 5: Classes da carta de uso e ocupação do solo de Portugal Continental para 2007.

#### 4.4 Fluxograma de procedimentos

Os procedimentos efetuados na classificação orientada a objetos e a segmentos foram desenvolvidos no *software* de processamento digital de imagem – *eCognition 9.0*. A figura 6 resume os procedimentos realizados.

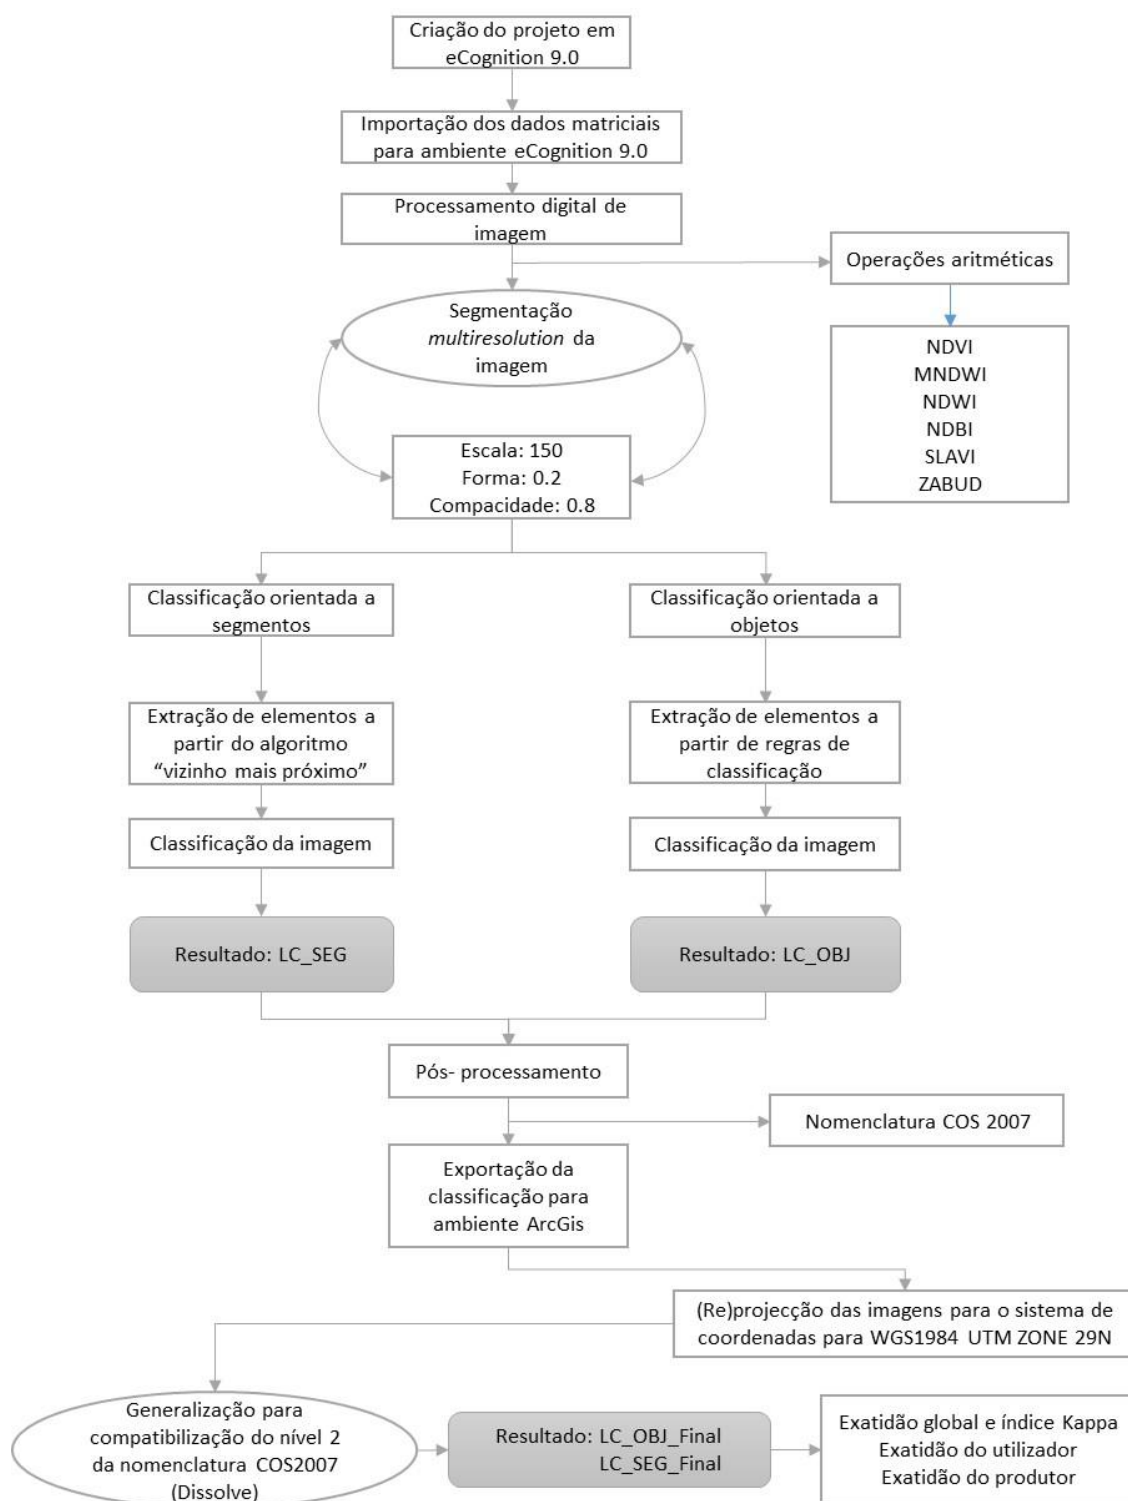


Figura 6: Fluxograma de procedimentos para a classificação orientada a objetos e segmentos.



Os procedimentos efetuados na classificação supervisionada orientada a pixel a pixel foi desenvolvida no *software* de processamento digital de imagem – ENVI 5.0. A figura 7 resume os procedimentos realizados.

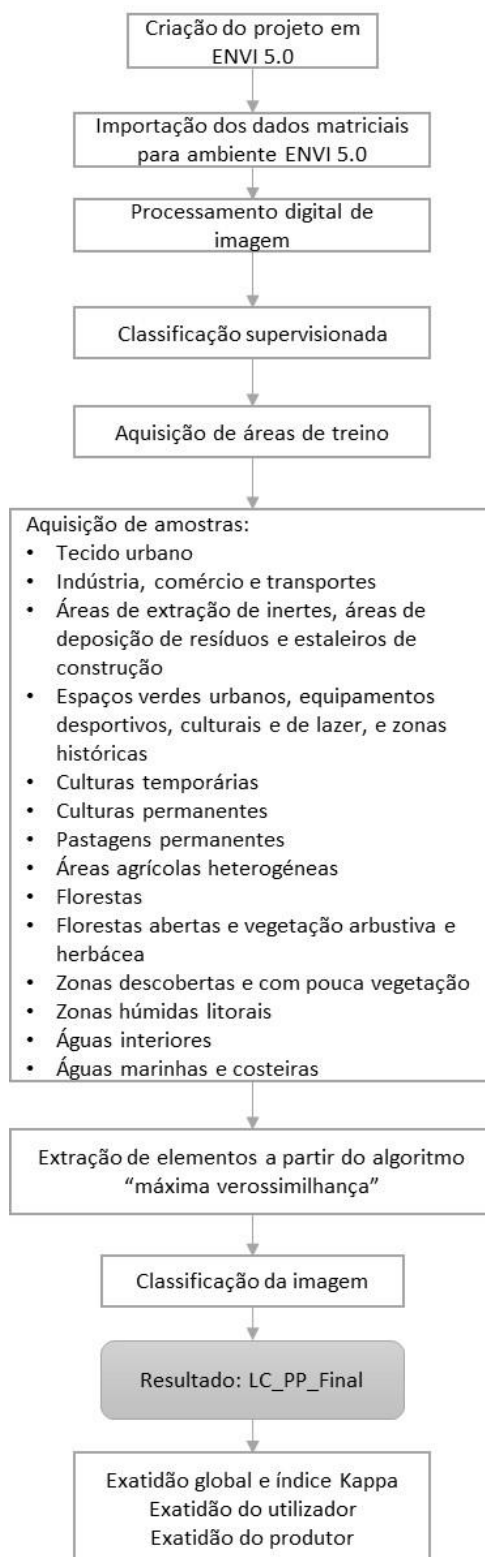


Figura 7: Procedimentos efetuados na classificação supervisionada orientada pixel a pixel.

## 4.5 Fusão da imagem

Numa primeira fase de pré-processamento procedeu-se a operações de melhoramento de imagem. A figura 8 resume os procedimentos efetuados na fusão da imagem.

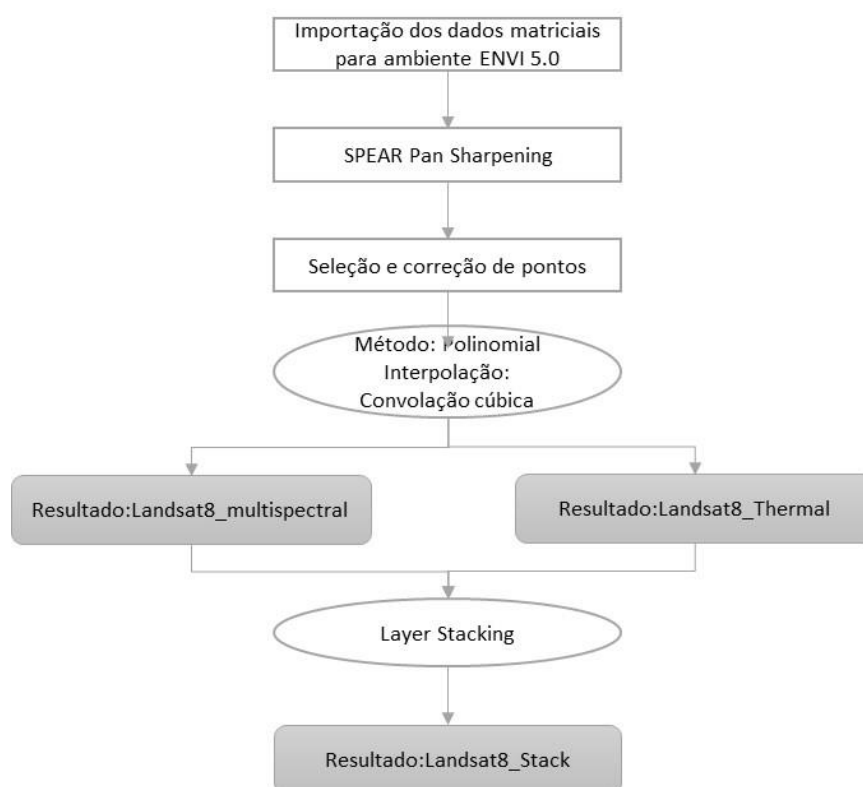


Figura 8: Procedimentos efetuados nos processos de melhoramento de imagem.

Primeiro, utilizou-se a técnica de fusão da imagem (*pan sharpening*). Zhang (2004), explica que é uma técnica usada de modo a integrar o detalhe geométrico de uma imagem de alta resolução pancromática, numa imagem multiespectral de baixa resolução, com o objetivo de produzir uma imagem multiespectral de alta resolução. Já Hofmann (2001) recomenda a técnica de fusão, afirmando que é uma etapa de pré-processamento indispensável antes de uma classificação orientada a objetos.

Ou seja a técnica de fusão de imagem a ser aplicada nesta dissertação tem como objetivo obter uma imagem que combine as características geométricas e espectrais da imagem pancromática, sem perder as suas características, a fim de obter uma imagem com uma resolução espacial de 15 m para as 8 bandas multiespectrais e das duas bandas do infravermelho-térmico, de modo a melhorar os desempenhos da segmentação e classificação.

O satélite *Landsat 8* deteta três tipos de imagens, as de baixa resolução que incluem as 8 bandas multiespectrais com 30 metros de resolução espacial e as duas bandas do infravermelho térmico com 60 metros. E capta uma imagem de alta resolução, a banda do pancromático com uma resolução espacial de 15 metros.

Utilizou-se a ferramenta “*SPEAR Pan Sharpening*” do ENVI 5.0 para a fusão da imagem. Utilizou-se a imagem pancromática como a imagem de alta resolução e como imagem de baixa resolução as 8 bandas multiespectrais.

Para o resultado do *pan sharpening* as imagens tem de se encontrar geometricamente alinhadas, visto que a informação do sistema de coordenadas não ser suficiente para o efeito. Para isso foram criados automaticamente 31 pontos de controlo (GCP), onde posteriormente foi possível eliminar os pontos que apresentavam um erro quadrático mais elevado. Ficando no final com um total de 23 pontos de controlo, como se pode observar na figura 9.

File	Options	Base X	Base Y	Warp X	Warp Y	Predict X	Predict Y	Error X	Error Y	RMS
#1+		1336.00	11168.00	6682.50	5584.50	6681.5176	5582.7844	-0.9824	-1.7156	1.9769
#2+		13306.00	8492.00	6653.50	4246.50	6651.7891	4244.3717	-1.7109	-2.1283	2.7307
#3+		11974.00	12276.00	5987.50	6138.50	5986.2163	6137.1050	-1.2837	-1.3950	1.8957
#4+		10559.00	13572.00	5280.00	6786.50	5277.8747	6785.5042	-2.1253	-0.9958	2.3470
#5+		11793.00	14940.00	5897.00	7470.50	5895.7029	7469.5923	-1.2971	-0.9077	1.5831
#6+		11818.00	13627.00	5909.50	6814.00	5908.1869	6812.8585	-1.3131	-1.1415	1.7399
#7+		11915.00	9808.00	5958.00	4904.50	5956.5816	4902.6817	-1.4184	-1.8183	2.3061
#8+		11779.00	8388.00	5890.00	4194.50	5889.5441	4192.4422	-1.4559	-2.0578	2.5208
#9+		10561.00	7192.00	5281.00	3596.50	5279.9759	3594.2823	-1.0241	-2.2177	2.4427
#10+		11974.00	1189.00	5987.50	3595.00	5985.9438	3592.7233	-1.5562	-2.2767	2.7578
#11+		7609.00	11175.00	3805.00	5588.00	3802.5201	5586.8182	-2.4799	-1.1818	2.7471
#12+		3598.00	12283.00	1799.50	6142.00	1794.5502	6141.5007	-4.9498	-0.4993	4.9749
#13+		2072.00	7287.00	1036.50	3644.00	1038.5260	3642.1625	2.0260	-1.8375	2.7352
#14+		2123.00	12471.00	1062.00	6236.00	1056.1185	6235.7145	-5.8815	-0.2855	5.8885
#15+		2058.00	9777.00	1029.50	4889.00	1027.7158	4887.9117	-1.7842	-1.0883	2.0899
#16+		2242.00	5887.00	1121.50	2944.00	1125.5685	2941.7376	4.0685	-2.2624	4.6552
#17+		2244.00	4594.00	1122.50	2297.50	1128.5100	2294.8519	6.0100	-2.6481	6.5676
#18+		2244.00	11030.00	1122.50	5515.50	1118.8401	5514.7715	-3.6599	-0.7285	3.7317
#19+		2092.00	8583.00	1046.50	4292.00	1046.5401	4290.5507	0.0401	-1.4493	1.4499
#20+		854.00	11059.00	427.50	5530.00	423.4602	5529.4068	-4.0398	-0.5932	4.0831
#21+		854.00	9751.00	427.50	4876.00	425.7162	4874.9933	-1.7838	-1.0067	2.0483
#22+		714.00	12471.00	357.50	6236.00	350.9593	6235.8684	-6.5407	-0.1316	6.5420
#23+		11974.00	10980.00	5987.50	5490.00	5986.1469	5488.8804	-1.3531	-1.1196	1.7562
#24+		13179.00	12381.00	6587.00	6187.50	6589.2683	6189.4930	2.2683	1.9930	3.0195
#25+		13271.00	3204.00	6638.50	1607.50	6632.9149	1599.5452	-5.5651	-7.9548	9.7197
#26+		6262.00	758.00	3146.00	383.00	3137.6267	375.8733	-8.3733	-7.1267	10.9955
#27+		9021.00	14868.00	4496.50	7431.00	4507.3418	7433.9676	10.8418	2.9676	11.2406
#28+		2244.00	3336.00	1129.50	1650.00	1130.4002	1665.4767	0.9002	15.4767	15.5029
#29+		11899.00	2067.00	5930.50	1029.50	5948.2591	1030.8336	17.7591	1.3336	17.8091
#30+		14693.00	5908.00	7348.00	2933.50	7343.7933	2951.9334	-4.2067	18.4334	18.9073
#31+		3607.00	13578.00	1776.50	6783.00	1797.3907	6789.3633	20.8907	6.3633	21.8384

File	Options	Base X	Base Y	Warp X	Warp Y	Predict X	Predict Y	Error X	Error Y	RMS
#1+		13364.00	11168.00	6682.50	5584.50	6682.5000	5584.4483	-0.0000	-0.0517	0.0517
#2+		13306.00	8492.00	6653.50	4246.50	6653.5000	4246.4556	-0.0000	-0.0444	0.0444
#3+		11974.00	12276.00	5987.50	6138.50	5987.5000	6138.4522	-0.0000	-0.0478	0.0478
#4+		10559.00	13572.00	5280.00	6786.50	5280.0000	6786.4566	-0.0000	-0.0434	0.0434
#5+		11793.00	14940.00	5897.00	7470.50	5897.0000	7470.4471	-0.0000	-0.0529	0.0529
#6+		11818.00	13627.00	5909.50	6814.00	5909.5000	6813.9499	-0.0000	-0.0501	0.0501
#7+		11915.00	9808.00	5958.00	4904.50	5958.0000	4904.4581	-0.0000	-0.0419	0.0419
#8+		11779.00	8388.00	5890.00	4194.50	5890.0000	4194.4618	-0.0000	-0.0382	0.0382
#9+		10561.00	7192.00	5281.00	3596.50	5281.0000	3596.4689	-0.0000	-0.0311	0.0311
#10+		11974.00	7189.00	5987.50	3595.00	5987.5000	3594.9638	-0.0000	-0.0362	0.0362
#11+		7609.00	11175.00	3805.00	5588.00	3805.0000	5587.9748	0.0000	-0.0252	0.0252
#12+		3598.00	12283.00	1799.50	6142.00	1799.5000	6141.9931	0.0000	-0.0069	0.0069
#13+		2072.00	7287.00	1036.50	3644.00	1036.5000	3643.9995	0.0000	-0.0005	0.0005
#14+		2123.00	12471.00	1062.00	6236.00	1062.0000	6236.0004	0.0000	0.0004	0.0004
#15+		2058.00	9777.00	1029.50	4889.00	1029.5000	4889.0001	0.0000	0.0001	0.0001
#16+		2242.00	5887.00	1121.50	2944.00	1121.5000	2943.9986	-0.0000	-0.0014	0.0014
#17+		2244.00	4594.00	1122.50	2297.50	1122.5000	2297.4984	-0.0000	-0.0016	0.0016
#18+		2244.00	11030.00	1122.50	5515.50	1122.5000	5515.4995	0.0000	-0.0005	0.0005
#19+		2092.00	8583.00	1046.50	4292.00	1046.5000	4291.9997	0.0000	-0.0003	0.0003
#20+		854.00	11059.00	427.50	5530.00	427.5000	5530.0059	0.0000	0.0059	0.0059
#21+		854.00	9751.00	427.50	4876.00	427.5000	4876.0052	0.0000	0.0052	0.0052
#22+		714.00	12471.00	357.50	6236.00	357.5000	6236.0073	0.0000	0.0073	0.0073
#23+		11974.00	10980.00	5987.50	5490.00	5987.5000	5490.4551	-0.0000	0.4551	0.4551

Figura 9: Correção dos pontos de controlo no processo *pan sharpening*.

Após a correção dos erros e a imagem estar geometricamente correta, procedeu-se à sua reamostragem, utilizando-se o algoritmo *cubic convolution*. Este método é utilizado de modo a determinar os níveis de cinzento em uma imagem. Isso é determinado pela média dos 16 pixéis das coordenadas de entrada, de seguida esse valor é registado nas coordenadas de saída. Este método é ligeiramente melhor que a interpolação bilinear e do método do vizinho mais próximo.

Por fim utilizou-se o método *Gram-Schmidt* para fundir a imagem, Laben & Brower (2000), referem que esse método melhora a resolução espacial da imagem multiespectral, unindo a imagem pancromática de alta resolução com a imagem de baixa resolução. Este processo realizou-se de igual modo para as duas bandas do infravermelho-térmico.

Após finalizado o processo de fusão de imagem, procedeu-se à combinação das 8 bandas multiespectrais com as duas bandas do infravermelho térmico em apenas um ficheiro, através da ferramenta “*layer stacking*”.




Figura 10: Resultado da fusão das bandas multiespectrais com a banda pancromática.



## 4.6 Extração de elementos e classificação de imagens orientadas de objetos

### 4.6.1 Extração de elementos e classificação de imagem a partir de algoritmia eCognition

#### 4.6.1.1 Segmentação Multiresolução

A abordagem orientada a objetos para a análise de imagens, os objetos, resultantes de um processo de segmentação são destinados a serem objetos do tipo primitivo, servindo como um veículo de informação e blocos de construção, para posterior classificação e outros processos de segmentação. Neste sentido, o melhor resultado da segmentação, é a que fornece informação otimizada para posterior processamento (Hofmann, Puzicha and Buhmann, 1998).

Em eCognition Baatz e Schäpe, (2000, citado por Encarnação, Rocha, Tenedório, & Estanqueiro 2007, p. 91) explica, que os objetos são construídos por segmentação multiresolução, uma técnica de crescimento de regiões. Neste processo, os objetos serão fundidos ou não, de acordo com critérios de decisão, nomeadamente o critério de homogeneidade (h) e o parâmetro de escala (Baatz *et al.*, 2003).

O primeiro passo na segmentação multiresolução é definir o peso a dar a cada imagem, ou seja, a importância que cada imagem vai possuir no processo da segmentação (tabela 6). Neste caso, apenas se deu o valor de 1 à banda do infravermelho, visto que é uma banda importante para a delimitação dos corpos de água e separar a vegetação saudável da não saudável.

Bandas	Designação	<i>Image layer weights</i>
B1	Costal Aerosol	0
B2	Azul	0
B3	Verde	0
B4	Vermelho	0
B5	Infravermelho próximo	1
B6	Infravermelho médio 1	0
B7	Infravermelho médio 2	0
B10	Infravermelho térmico	0
B11	Infravermelho térmico	0

Tabela 6: Peso das bandas Landsat 8 no processo de segmentação.

O segundo passo, passa por definir o parâmetro escala, e o critério de homogeneidade, que inclui a forma e a compacidade.

O parâmetro escala determina a heterogeneidade dos objetos. Os objetos resultantes de dados heterogêneos irão ser menores do que dados homogêneos. Ao variar o parâmetro escala, os objetos criados vão variar de tamanho.

O parâmetro da forma modifica a relação entre os critérios, forma e cor. Aumentando ou diminuindo o seu valor, define-se a percentagem com que os valores espectrais da imagem irão contribuir para a homogeneidade dos objetos.

O critério da compacidade é usado para otimizar os objetos em uma imagem. Este critério deve ser utilizado quando diferentes objetos na imagem estão bastante compactos, mas estão separados por objetos não compactos apenas por um contraste espectral relativamente fraco.

Várias experiências de segmentações foram realizadas, até se ter concluído que os valores obtidos na tabela 7, eram os ideais para a imagem *Landsat 8*, tendo sido criados 861.962 objetos. Nesta fase, cabe ao utilizador, a responsabilidade de determinar qual a melhor segmentação que representa os objetos a serem representados na classificação.

Critérios utilizados na segmentação	
Critérios	Valor
Escala	150
Forma	0.2
Compacidade	0.8

Tabela 7: Critérios utilizados na segmentação.

Através do conjunto de imagens na figura 11, podemos observar um delineamento dos objetos muito bom, como por exemplo os corpos de água, áreas agrícolas e o tecido urbano, chegando a segmentar as pontes.




Figura 11: Resultado do processo de segmentação *multiresolution*.

#### 4.6.1.2 Extração de elementos

O *eCognition* suporta diferentes técnicas de classificação supervisionada e métodos diferentes para gerar áreas de interesse e contruir uma base de conhecimento para a classificação orientada a objetos de uma imagem. A estrutura base de conhecimento para a análise e classificação de objetos de uma imagem é chamada hierarquia de regras. As regras podem ser agrupadas numa forma hierárquica, permitindo o agrupamento semântico das mesmas. Este formato simples de agrupamento hierárquico oferece uma variadíssima e surpreendente para a formulação de semântica da imagem e para diferentes estratégias de análise. O utilizador interage com o processo e com base em estatísticas, textura, forma e relações de vizinhança entre os objetos, define áreas de interesse. A classificação de um objeto pode seguir o método “vizinho mais próximo” ou a lógica “fuzzy” de funções de pertinência (Manakos, 2001).

O método “fuzzy” de extração de objetos a partir de regras de classificação, cada classe tem um conjunto de regras que permitem a avaliação de características específicas e operações lógicas. A regra pode ter uma única condição ou podem consistir em uma combinação de várias condições que tem de ser cumpridas para que o objetos sejam corretamente classificado e seja atribuída a uma classe de ocupação do solo. Uma classe também pode incluir não só uma regra, mas um conjunto de regras, com várias operações lógicas e de análise espacial.

As regras de classificação efetuadas foram desenvolvidas no *software* de processamento digital de imagem – *eCognition* 9.0. A tabela 8 resume os procedimentos realizados.

Classes de ocupação do solo (nível2)	Regras de classificação
Tecido urbano	<ul style="list-style-type: none"> <li>unclassified with mode[Maximum](Roughness) &lt;= 35000 at Nivel 1: 1.1 *</li> <li>1.1 with NDVI &lt; 0.1 at Nivel 1: 1.1</li> </ul>
Indústria, comércio e transportes	<ul style="list-style-type: none"> <li>with Length &lt;= 21000 at Nivel 1: estradas</li> <li>with Brightness &lt;= 35000 at Nivel 1: 1.2</li> <li>unclassified at Nivel 1: estradas, 1.2 *</li> </ul>
Áreas de extração de inertes, áreas de deposição de resíduos e estaleiros de construção	<ul style="list-style-type: none"> <li>unclassified with Brightness &gt;= 35000 at Nivel 1: 1.3 *</li> </ul>
Espaços verdes urbanos, equipamentos desportivos, culturais e de lazer, e zonas históricas	<ul style="list-style-type: none"> <li>unclassified with Rel. border to 1.1 &gt; 0.5 and NDVI &gt; 0.3 at Nivel 1: 1.4</li> </ul>
Culturas temporárias	<ul style="list-style-type: none"> <li>unclassified at Nivel 1: 2.1 *</li> <li>set rule set options</li> <li>edge extraction lee sigma (5.0, Dark) 'Layer 1' =&gt; 'LeeSigmaDark'</li> <li>edge extraction lee sigma (5.0, Bright) 'Layer 1' =&gt; 'LeeSigmaBright'</li> <li>layer arithmetics (val "LeeSigmaDark+LeeSigmaBright", layer LeeSigmaSum[float])</li> <li>Roughness = Gaussian(LeeSigmaSum, 31 x 31 x 1)</li> <li>30 [shape:0.2 compct.:0.8] creating 'New Level'</li> <li>with cstm Vegetation Roughness &lt;= 35 at New Level: Rough or Elevated Vegetation</li> </ul>
Culturas permanentes	<ul style="list-style-type: none"> <li>unclassified with Brightness &lt; 19000 and X distance to scene right border &gt;= 8000 Pxl at Nivel 1: 2.2 *</li> </ul>
Pastagens permanentes	<ul style="list-style-type: none"> <li>unclassified with cstm Vegetation Roughness &lt; 30 at Nivel 1: 2.3 *</li> </ul>
Áreas agrícolas heterogéneas	<ul style="list-style-type: none"> <li>unclassified with Border to 2.1 = 0.5 Pxl and NDVI &gt;= 0.25 at Nivel 1: 2.4</li> </ul>
Florestas	<ul style="list-style-type: none"> <li>unclassified with NDVI &gt; 0.35 and Brightness &gt;= 17000 at Nivel 1: 3.1 *</li> </ul>
Florestas abertas e vegetação arbustiva e herbácea	<ul style="list-style-type: none"> <li>unclassified with NDVI &gt;= 0.15 and Brightness &lt;= 17000 at Nivel 1: 3.2</li> </ul>
Zonas descobertas e com pouca vegetação	<ul style="list-style-type: none"> <li>3.3 with SLAVI &gt; 0.5 and cstm Brightness &gt;= 17000 at Nivel 1: praia, 3.3</li> <li>with NDVI &lt;= 0.15 at Nivel 1: praia, 3.3</li> </ul>
Zonas húmidas litorais	<ul style="list-style-type: none"> <li>unclassified with NDVI &lt; 0.2 at Nivel 1: 4.2</li> <li>unclassified with Rel. border to 5.2 = 1 and Rel. border to 5.1 = 1 at Nivel 1: 4.1</li> </ul>
Águas interiores	<ul style="list-style-type: none"> <li>unclassified with Mean NIR &lt; 15000 and Length &gt; 200 at Nivel 1: 5.1</li> </ul>
Águas marinhas e costeiras	<ul style="list-style-type: none"> <li>unclassified with Mean NIR &lt; 15000 and Area &gt; 20000000 at Nivel 1: 5.2</li> <li>unclassified with Mean NIR &lt; 15000 and Rel. border to 5.2 &gt; 0 at Nivel 1: missed water</li> <li>5.2 at Nivel 1: merge region</li> <li>5.2 at Nivel 1: &lt;- missed water</li> </ul>

Tabela 8: Regras de classificação realizadas para a classes de ocupação do solo da COS 2007.

No *tecido urbano* (1.1) utilizou-se a rugosidade dos objetos, de modo a diferenciar os *territórios artificializados* (1) das *florestas* (3.1), visto que possuem texturas mais rugosas. Juntamente com a rugosidade, e de modo a ser possível atingir separabilidade espectral entre áreas agrícolas e florestas abertas, usou-se o NDVI, já que os seus valores nos territórios artificializados são muito baixos ou nulos.

Na classe *indústrias, comércio e transportes* (1.2) teve-se que separar em duas classes, de modo a poder classificar as estradas e edifícios industriais e comerciais. Para as estradas (transportes) utilizou-se a regra comprimento, visto que, durante o processo de segmentação, as estradas produziram segmentos de grande comprimento, com pouca largura. Para as indústrias e comércio utilizou-se o brilho, visto que, os edifícios utilizam uma cobertura com uma elevada refletância espectral, o que facilmente possibilita a sua classificação, juntamente com o brilho, também utilizou-se o NDVI. Posteriormente, já no *ArcGis*, uniu-se as estradas à classe de indústrias e comércio para uma só classe, fazendo a classe *industrias, comércio e transportes* (1.2).

As *áreas de extração de inertes, áreas de deposição de resíduos e estaleiros de construção* (1.3) utilizou-se o critério do brilho, visto serem áreas de solo exposto, produzindo uma elevada refletância espectral, uma das vantagens do eCognition 9.0, é uma classe ao ser classificada, outras classes ao serem classificadas não se vão sobrepor à anterior, portanto, podemos utilizar o critério brilho sem afetar a classe de *industrias, comercio e transportes* (1.2).

Os *Espaços verdes urbanos, equipamentos desportivos, culturais e de lazer, e zonas históricas* (1.4), apresentou-se como uma classe difícil de classificar, devido a ser uma classe composta por vários objetos de assinaturas espectrais diferentes, semelhantes ao *tecido urbano* (1.1). De modo a solucionar este problema, procedeu-se à criação de várias classes, os espaços verdes urbanos e equipamentos desportivos, sendo ocupações do solo próximas ao *tecido urbano* (1.1) e com o NDVI elevado, utilizou-se a relação de fronteira juntamente com um valor de NDVI igual ou maior a 0.3. As áreas culturais e de lazer, e zonas históricas provou-se muito difícil de encontrar regras de classificação adequadas, desde modo, ficaram agregadas ao *tecido urbano* (1.1).

Para as *culturas temporárias* (2.1) produziu-se uma hierarquia de regras (fuzzy) de modo a ser possível distinguir as *culturas temporárias* (2.1) das *florestas* (3.1). Através do algoritmo *edge extraction lee sigma*, produziu-se dois filtros, servindo para deteção de bordas claras e escuras (figura 12).






Figura 12: Resultados do algoritmo *edge extraction lee sigma*.

De seguida realizou-se uma operação aritmética, somando-se os dois filtros (figura 13).




Figura 13: Resultado da operação aritmética do algoritmo *edge extraction lee sigma*

Com o resultado da operação aritmética, utilizou-se o algoritmo “*Gaussian*”, com o objetivo de suavizar a superfície, e permitir a distinção de uma superfície rugosa de uma superfície lisa (figura 14), permitindo a classificação das *culturas temporárias* (2.1).




Figura 14: Resultado do algoritmo Gaussian.

Nas *culturas permanentes* (2.2), foi utilizado o critério distância ao direito da imagem, visto que a grande percentagem das *culturas permanentes* (2.2) encontram-se do lado direito da imagem, juntamente com o critério da distancia, usou-se o critério brilho, visto que são solos com alto refletância espectral.

As pastagens permanentes, provou ser uma classe de difícil classificação, apresentando maus desempenhos, para isso, utilizou-se a superfície criada para as culturas temporárias, alterando apenas os valores.

Para as áreas agrícolas heterogêneas

Na classe das *florestas* (3.1) utilizou-se o NDVI superior a 0.35, visto que serem áreas onde existe uma elevada produção de clorofila e com um brilho superior a 17000.

Nas *florestas abertas e vegetação arbustiva e herbácea* (3.2) utilizou-se novamente o NDVI, mas desta vez, com um valor inferior a 0.15, visto que, ao contrário das florestas (3.1), são zonas onde a produção de clorofila é mais reduzida, também foi utilizado o critério brilho inferior a 17000.

Para a classe das *zonas descobertas e com pouca vegetação* (3.3), separou-se em duas classes, de modo a classificar solos expostos e praias. Para os solos expostos (rocha nua), utilizou-se o índice SLAVI (Specific leaf area vegetation index), de modo a permitir classificar as áreas onde não exista vegetação, juntamente com o SLAVI, usou-se o critério brilho, visto serem solos com uma elevada refletância espectral. Para as praias utilizou-se o comprimento e a relação de fronteira com as *águas marinhas e costeiras* (5.2).



Para as *zonas húmidas litorais* (4.2) utilizou-se o NDVI inferior a 0.2 e relações de fronteira com as *águas interiores* (5.1) e as *águas marinhas e costeiras* (5.2). Deste modo permitiu que solos com valores superiores a 0 de NDVI e que se situassem entre as águas interiores (5.1) e *águas marinhas e costeiras* (5.2) fossem classificadas como *zonas húmidas litorais* (4.2).

A classe das *águas interiores* (5.1) utilizou-se a banda do infravermelho próximo, devido à elevada absorção espectral dos corpos de água nessa banda, com um valor inferior a 15000. Juntamente com a banda do infravermelho próximo, utilizou-se o critério geométrico comprimento, posteriormente foi realizado um “merge” através dos dois critérios.

Nas classes das águas marinhas e costeiras (5.2), usou-se a banda do infravermelho próximo, com um valor inferior a 15000 e o critério geométrico de área, visto o processo de segmentação ter produzido segmentos de elevada dimensão com elevada homogeneidade, posteriormente realizou-se um “merge” de todos os segmentos, com os critérios acima referidos.

## 4.7 Cálculo para avaliação de exatidão de temática

Em detecção remota o cálculo para a avaliação de exatidão temática é uma ferramenta indispensável e um indicador de qualidade para a avaliação do mapa criado, segundo Congalton e Green (1999, p. 2), a exatidão de temática determina a qualidade do mapa criado a partir de dados de detecção remota. A exatidão de temática pode ser qualitativa ou quantitativa, económica ou dispendiosa, rápida ou demorada, bem desenhada, eficiente ou casual. O objetivo da exatidão de temática quantitativa é a identificação e a determinação dos erros do mapa.

Segundo Lillesand, *et al* (2008), historicamente, a capacidade de produzir classificações de ocupação do solo excedia a capacidade de avaliar a sua exatidão. Na verdade, este problema limitava a aplicação de técnicas de ocupação do solo automáticas, mesmo quando o seu custo, comparado com outros meios de recolha de dados fossem mais económicos. A lição a ser aprendida é incorporada na expressão “A classificação de uma imagem não está completa até que a sua precisão seja avaliada”.

Já Campbell e Wynne (2011), consideram que a exatidão define “correção”, mede o acordo entre um padrão assumido que é correto e uma imagem classificada de qualidade desconhecida. Se a imagem classificada corresponde com a norma, é dito ser precisa. Existem vários métodos para medir o grau de correspondência. A exatidão define a medida de certeza. Em detecção remota, a exatidão tem duas conotações: (1) a especificidade categórica de um mapa temático e (2) o intervalo de confiança dentro do qual o nível de exatidão se enquadra.

Contudo, o cálculo para a avaliação da exatidão temática para a classificação de imagens orientada a objetos ainda não é consensual entre os vários autores.

Zhang *et al* (2010), propõe um novo método de avaliação de exatidão para a classificação de imagens orientada a objetos. Ele mede tanto a precisão geométrica como a precisão temática dos objetos. A precisão geométrica é medida a partir de dois aspetos, área e precisão limite. A precisão temática é medida através da associação dos objetos. Testes mostram que o método pode fornecer mais informações sobre o nível de exatidão da classificação e o potencial para resolver problemas das medidas tradicionais de exatidão estatística.

Já Radoux *et al* (2010) propõe um método diferente. A classificação de imagens orientada a objetos pode ser usada para a avaliação da exatidão temática de “geographic object-based image analysis”. Neste estudo um novo método da avaliação da exatidão temática foi proposto, requer menos unidades de amostragem do que outros métodos baseados em pontos.

Clinton *et al* (2008) consideraram a extração de edifícios e veículos em área urbana, optaram por delinear um mapa de referência com a distribuição espacial das duas classes de interesse e avaliar a sua exatidão, ou seja, os Edifícios e os veículos; superando assim a lentidão e dificuldade de criar um mapa inteiro de referência para toda a imagem.

#### 4.7.1 Matriz de confusão

A matriz de confusão é uma ferramenta útil na detecção remota, servindo para avaliar o nível de exatidão temática, relacionando a classificação da imagem com os dados de referência.

Através da matriz de confusão podemos calcular o desempenho geral da exatidão temática, o índice de concordância *Kappa*, erro de comissão e omissão e a exatidão do utilizador e produtor.

Story e Congalton (1986) foram os primeiros a introduzir a matriz de confusão na comunidade de informação geográfica, os autores explicam, que a matriz de confusão, além de mostrar os erros de omissão e comissão, também pode ser usada para calcular a exatidão global (*overall accuracy*), a exatidão do produtor e do utilizador.

Uma matriz de confusão é uma matriz composta por números estruturados em linhas e colunas, expressando o número de unidades na amostra, atribuídas a uma categoria de uma classificação relativamente ao número de unidades na amostra de outra classificação. Na maioria dos casos, uma das classificações é considerada correta (dados de referência), e podem ser gerados a partir de fotografias aéreas, observação do terreno. As colunas normalmente representam os dados de referência, enquanto as linhas os dados da classificação gerada a partir de dados de detecção remota (Congalton e Green, 1999, p. 57).

		Dados de referência					
Dados Classificados		1	2	k	Total $n_{+i}$	Exatidão do utilizador (%)	Erro de comissão (%)
	1	$n_{11}$	$n_{12}$	$n_{1k}$	$n_{1+}$	$(n_{11}/n_{1+}) * 100$	$(n_{1+} - n_{11}) / n_{1+} * 100$
	2	$n_{21}$	$n_{22}$	$n_{2k}$	$n_{2+}$	$(n_{22}/n_{2+}) * 100$	$(n_{2+} - n_{22}) / n_{2+} * 100$
	k	$n_{k1}$	$n_{k2}$	$n_{kk}$	$n_{k+}$	$(n_{kk}/n_{k+}) * 100$	$(n_{k+} - n_{kk}) / n_{k+} * 100$
	Total $n_{+j}$	$n_{+1}$	$n_{+2}$	$n_{+k}$	$n$		
	Exatidão do produtor (%)	$(n_{11}/n_{+1}) * 100$	$(n_{22}/n_{+2}) * 100$	$(n_{kk}/n_{+k}) * 100$			
	Erro de omissão (%)	$(n_{+1} - n_{11}) / n_{+1} * 100$	$(n_{+2} - n_{22}) / n_{+2} * 100$	$(n_{+k} - n_{kk}) / n_{+k} * 100$			

Tabela 9: Exemplo matemático da matriz de confusão. Fonte: Congalton e Green (1999) (adaptado).

O cálculo do *overall accuracy*, entre a classificação da imagem e os dados de referência, podem ser calculados através da seguinte equação:

$$Overall\ accuracy = \frac{\sum_{i=1}^k n_{ii}}{n}$$

#### 4.7.2 Índice de concordância *Kappa*

O índice de concordância *Kappa* é outra medida de avaliação de qualidade da classificação de imagens, possível de realizar através da matriz de confusão.

Segundo Congalton e Green (1999), este coeficiente é baseado na diferença da concordância observada (entre a classificação da imagem e os dado de referência na diagonal principal da matriz) e a concordância indicada pelo total das linhas e colunas.

O resultado do índice de concordância *Kappa* é dado através da seguinte equação:

$$Kappa = \frac{n \sum_{i=1}^k n_{ii} - \sum_{i=1}^k n_{i+n_i}}{n^2 - \sum_{i=1}^k n_{i+n_i}}$$

Onde:

$k$  = numero de linhas (classes) na matriz de confusão

$n_{ii}$  = total de elementos classificados na linha  $i$  e coluna  $i$

$n_{i+}$  = total de elementos classificados na linha  $i$

$n_{+i}$  = total de elementos classificados na coluna  $i$

$N$  = número total de amostras incluídas na matriz de confusão

Landis e Koch (1977) propuseram a seguinte escala de avaliação da qualidade da classificação de imagens em detecção remota

Qualidade da classificação do índice <i>Kappa</i>	
Índice <i>Kappa</i> (K)	Características
<0,00	Péssima
0,00 – 0,20	Má
0,20 – 0,40	Razoável
0,40 – 0,60	Boa
0,60 – 0,80	Muito boa
0,80 – 1,00	Excelente

Tabela 10: Qualidade da classificação do índice *Kappa*.

#### 4.7.3 Cálculo da exatidão do utilizador e produtor, erro de comissão e omissão

##### 4.7.3.1 Exatidão do produtor

A exatidão do produtor refere-se à probabilidade de determinada classe, estar corretamente classificada de acordo com os dados de referência.

Lillesand *et al* (1999), explica que a exatidão do produtor resulta da divisão do número de pixéis classificados corretamente em cada classe (na diagonal principal) pelo número total de pixéis classificados nessa classe (total da coluna).

A exatidão do produtor resulta através da seguinte equação:

$$Exatidão\ do\ produtor = \frac{n_{ii}}{n_{+i}} * 100$$

Onde:

$n_{ii}$  = total de elementos classificados na linha  $i$  e coluna  $i$

$$n_{+i} = \text{total}$$

#### 4.7.3.2 Exatidão do utilizador

A exatidão do utilizador indica a probabilidade de uma classe classificada na imagem corresponda a mesma classe no terreno.

Lellisand *et al* (1999) explica que a exatidão do utilizador é calculada através da divisão dos pixéis classificados (diagonal principal) corretamente em cada classe, pelo número total de pixéis de cada classe (total da linha).

A exatidão do utilizador resulta através da seguinte equação:

$$\text{Exatidão do utilizador} = \frac{n_{ii}}{n_{i+}} * 100$$

Onde:

$n_{ii}$  = total de elementos classificados na linha  $i$  e coluna  $i$

$n_{i+}$  = total de elementos classificados na linha  $i$

#### 4.7.3.3 Erro de comissão

Um erro de comissão é quando uma área é incluída em uma classe de ocupação do solo e na realidade não corresponde a essa classe.

$$\text{Erro de comissão} = \frac{n_{i+n_{ii}}}{n_i} * 100$$

#### 4.7.3.4 Erro de omissão

Um erro de omissão acontece quando uma área é excluída de uma classe ed ocupação do solo, quando na realidade ela corresponde a essa mesma classe.

$$\text{Erro de omissão} = \frac{n_{+1-n_{11}}}{n_{+1}} * 100$$

## 4.8 Resultados

### 4.8.1 Resultados da abordagem pixel a pixel

#### 4.8.1.1 Resultado da classificação orientada pixel a pixel (10 classes)

Apresenta-se na figura 15 a classificação supervisionada da imagem pela abordagem pixel a pixel para 10 classes, com recurso ao algoritmo vizinho mais próximo (*nearest neighbour*). Executado pelo *software Envi 5.0*.

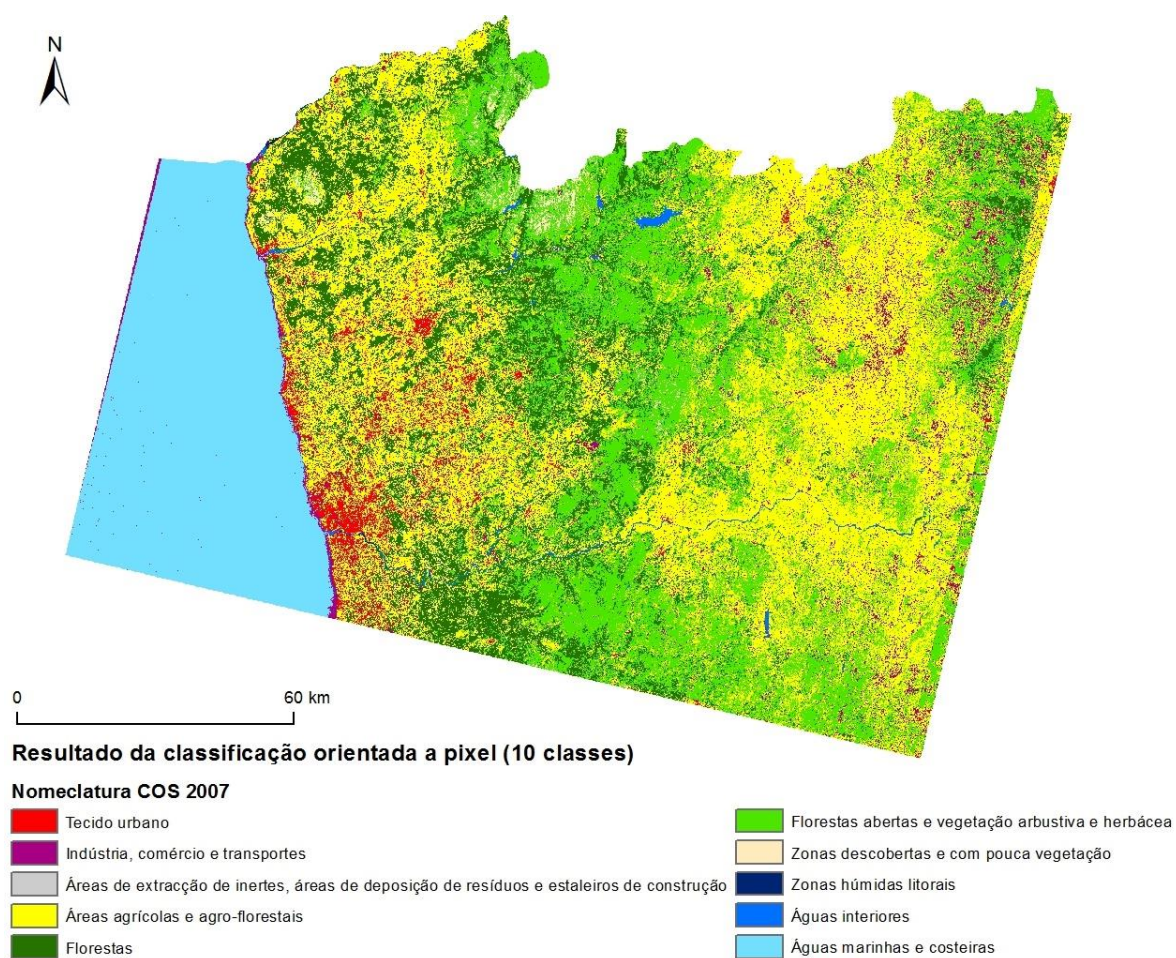


Figura 15: Resultado da classificação orientada a pixel (10 classes).

#### 4.8.1.2 Resultado da classificação orientada pixel a pixel (14 classes)

Apresenta-se na figura 16 a classificação supervisionada da imagem pela abordagem pixel a pixel para 14 classes, com recurso ao algoritmo vizinho mais próximo (*nearest neighbour*). Executado pelo *software Envi 5.0*.

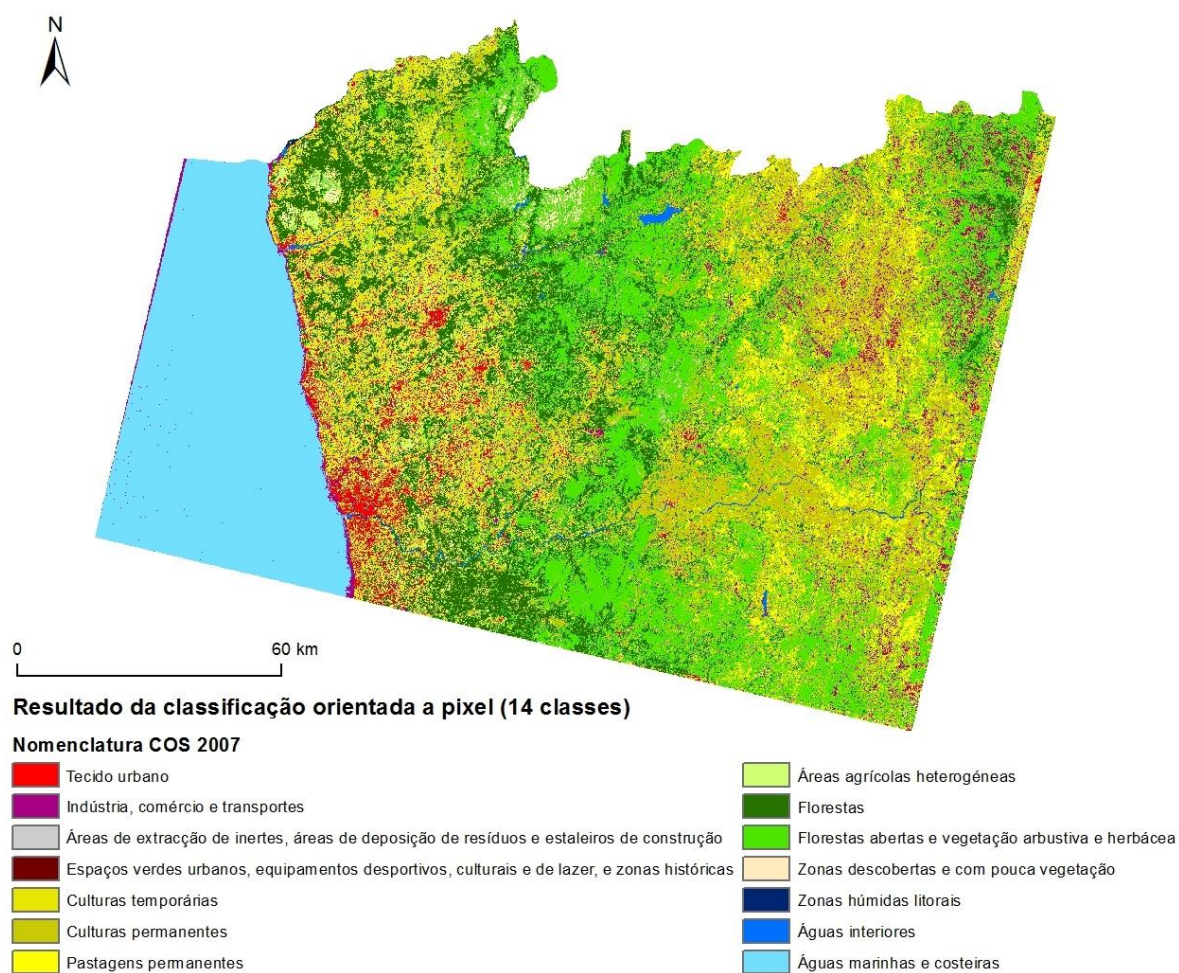


Figura 16: Resultado da classificação orientada a pixel (14 classes).



## 4.8.2 Resultados da abordagem orientada a segmentos

### 4.8.2.1 Resultado da classificação orientada a segmentos (10 classes)

Apresenta-se na figura 17 o resultado final obtido pela classificação orientada a segmentos para 10 classes, com recurso ao algoritmo vizinho mais próximo (*nearest neighbour*). Executado pelo *software eCognition 9.0*.

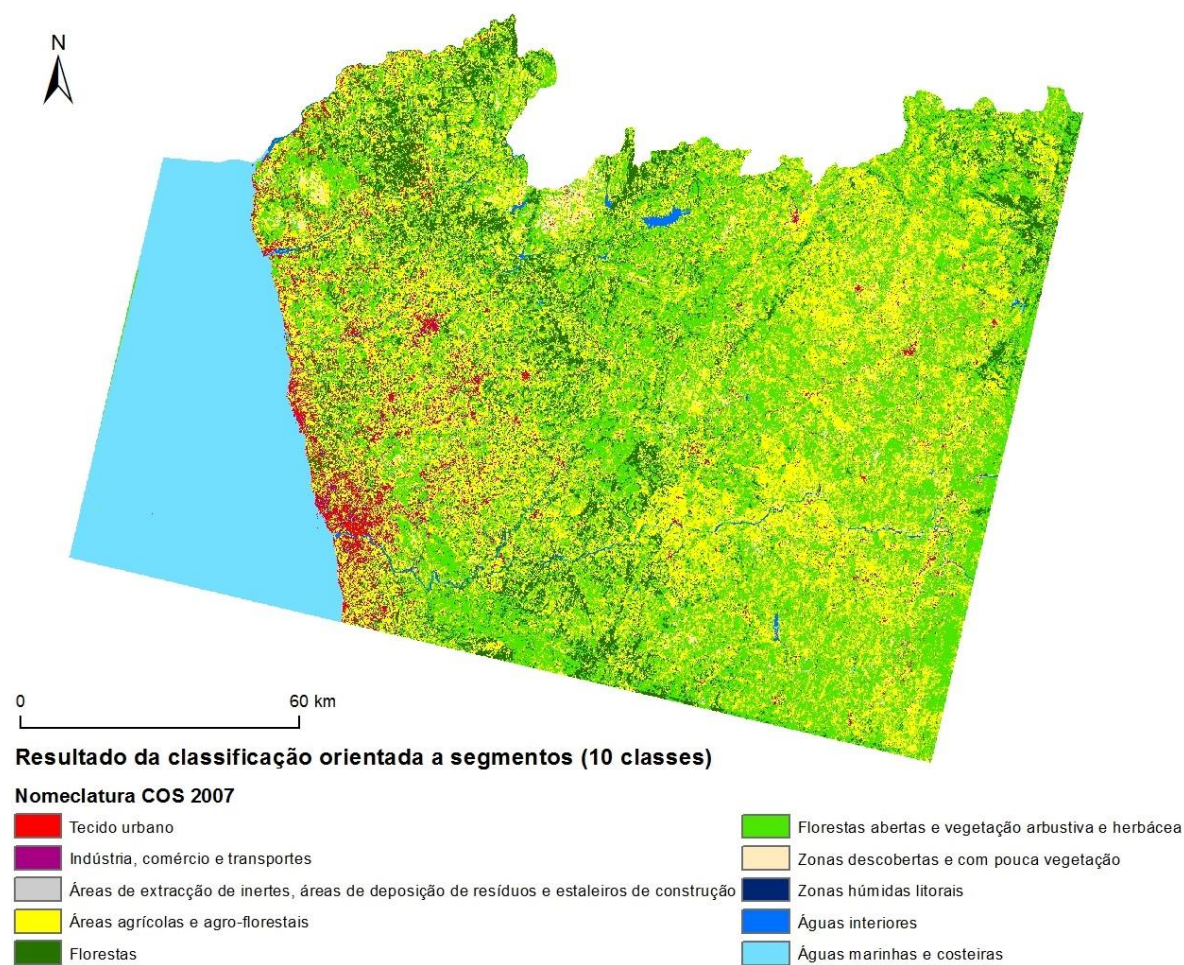


Figura 17: Resultado da classificação orientada a segmentos (10 classes).

#### 4.8.2.2 Resultado da classificação orientada a segmentos (14 classes)

Apresenta-se na figura 18 o resultado final obtido pela classificação orientada a segmentos para 14 classes, com recurso ao algoritmo vizinho mais próximo (*nearest neighbour*). Executado pelo *software eCognition 9.0*.

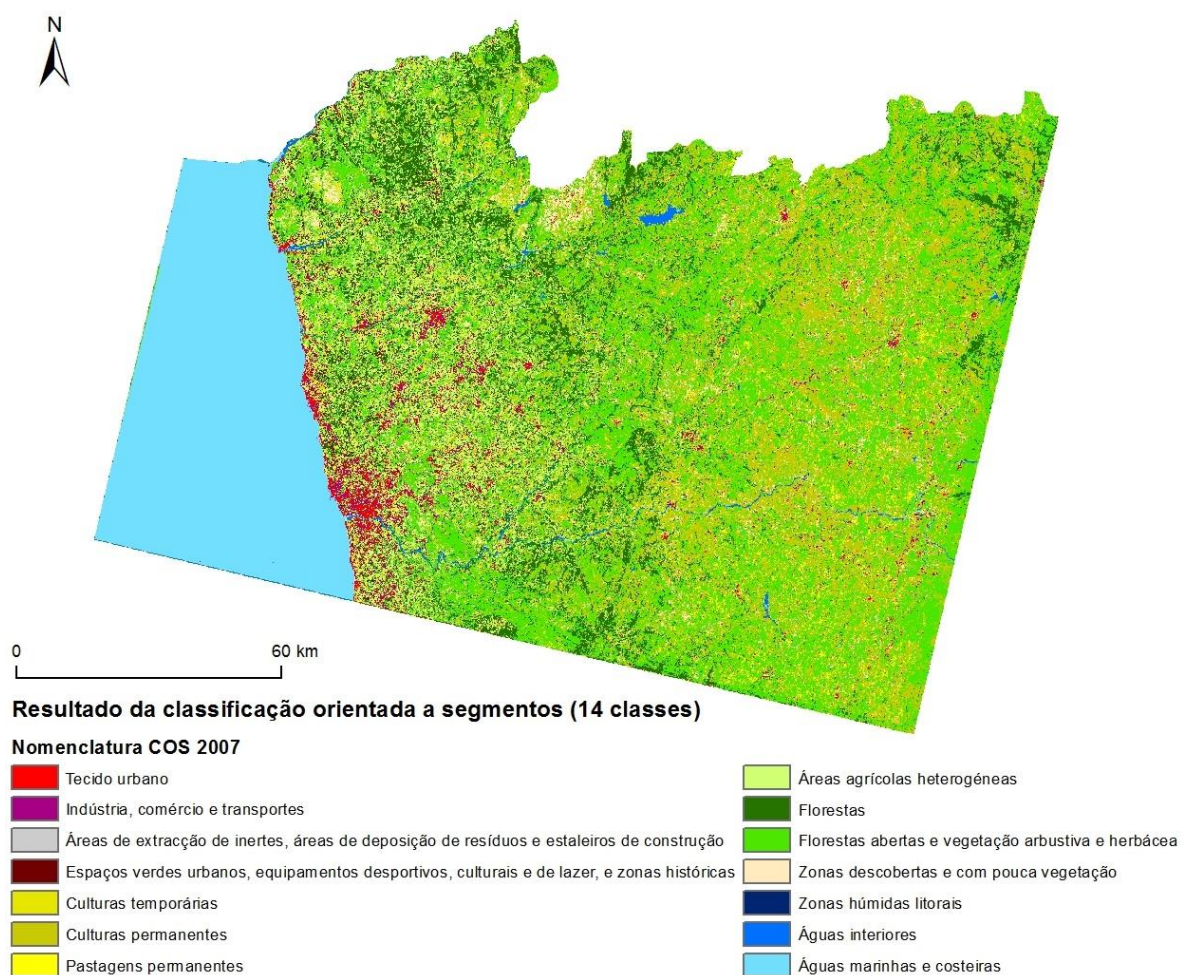


Figura 18: Resultado da classificação orientada a segmentos (14 classes).



### 4.8.3 Resultados da abordagem orientada a objetos

#### 4.8.3.1 Resultados da classificação orientada a objetos (10 classes)

Apresenta-se na figura 19 o resultado final obtido pela classificação orientada a objetos para 10 classes. Executado pelo *software eCognition 9.0*.

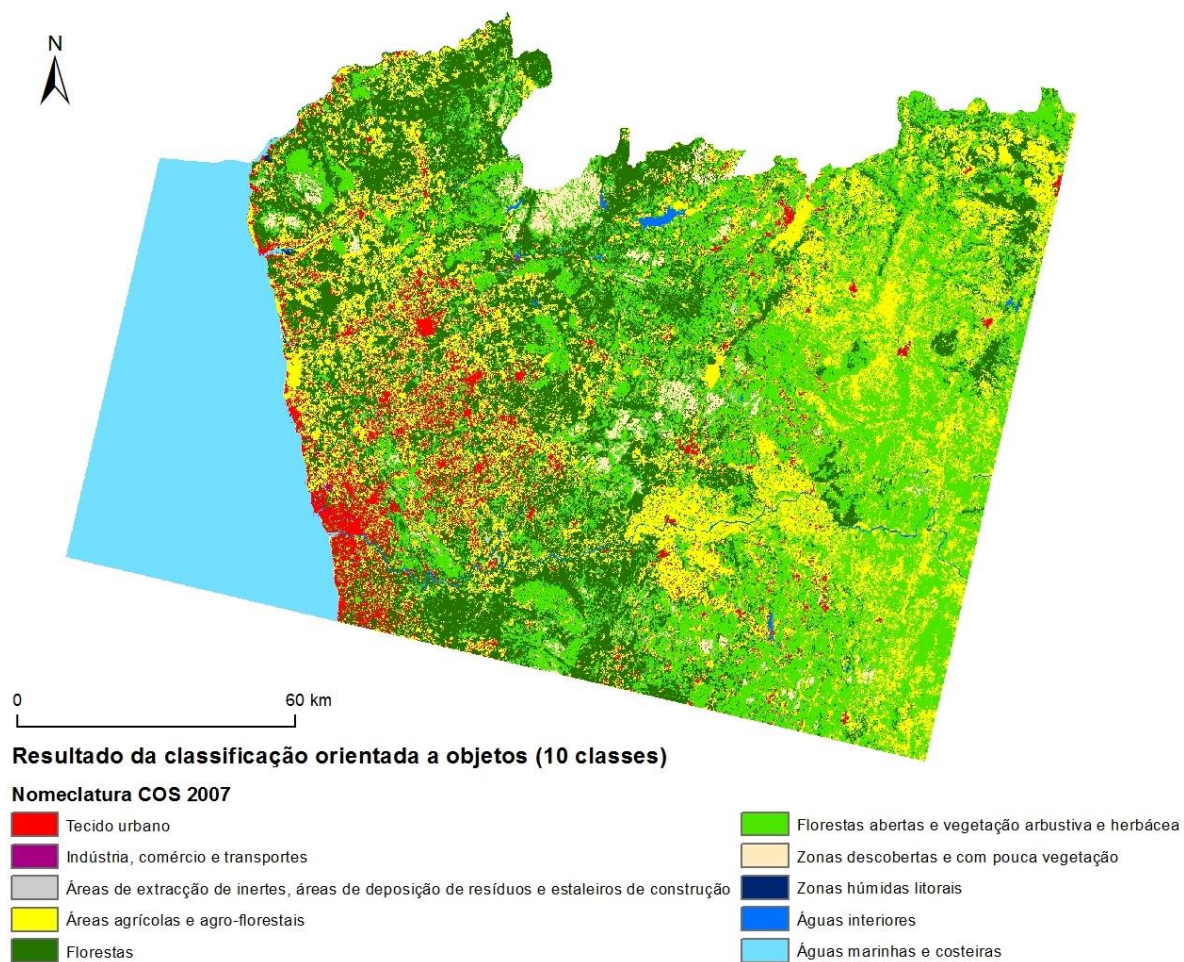


Figura 19: Resultado da classificação orientada a objetos (10 classes).

#### 4.8.3.2 Resultados da classificação orientada a objetos (14 classes)

Apresenta-se na figura 20 o resultado final obtido pela classificação orientada a objetos para 14 classes. Executado pelo *software eCognition 9.0*.





Figura 20: Resultado da classificação orientada a objetos (14 classes).

## 5. Capítulo V: discussão de resultados


Neste capítulo apresenta-se a classificação resultante de cada abordagem adotada, e os respectivos resultados das matrizes de confusão.

A figura 21 e 22 mostra a comparação do classificador orientado a objeto, segmentos e pixel com a carta de uso e ocupação do solo de 2007, para uma determinada área da imagem *Landsat* 8. Os valores da comparação neste estudo são a exatidão global e o índice *Kappa*, e os respectivos, erros de omissão, comissão, exatidão do produtor e utilizador.







Classificação orientada a objetos



Classificação orientada a segmentos



Classificação orientada a pixel



Carta de ocupação do solo 2007

**Nomenclatura COS 2007**

- Tecido urbano
- Indústria, comércio e transportes
- Áreas de extração de inertes, áreas de deposição de resíduos e estaleiros de construção
- Espaços verdes urbanos, equipamentos desportivos, culturais e de lazer, e zonas históricas
- Culturas temporárias
- Culturas permanentes
- Pastagens permanentes

- Áreas agrícolas heterogêneas
- Florestas
- Florestas abertas, vegetação arbustiva e herbácea
- Zonas descobertas e com pouca vegetação
- Zonas húmidas interiores
- Águas interiores
- Águas marinhas e costeiras



Figura 21: Comparação entre os vários classificadores com a carta de uso e ocupação do solo de 2007 (14 classes).



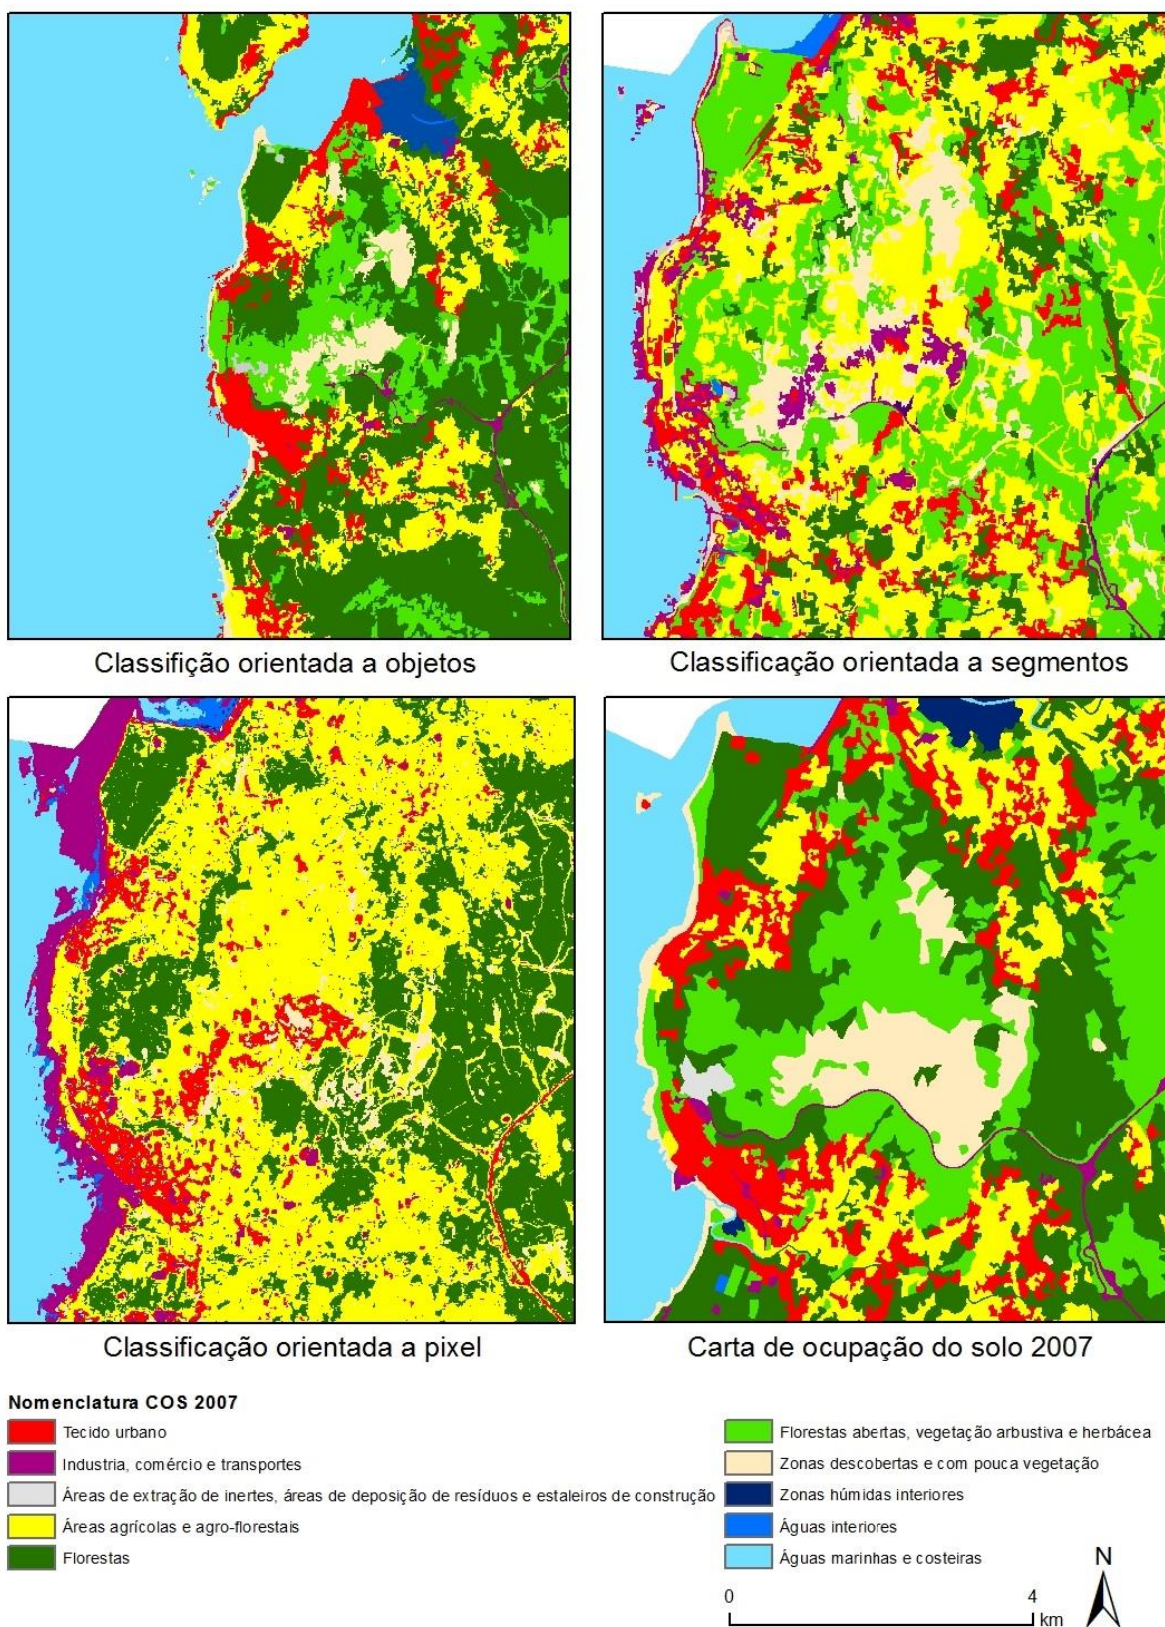



Figura 22: Comparação entre os vários classificadores com a carta de uso e ocupação do solo de 2007 (10 classes).

Comparando a classificação orientada a objetos com a classificação orientada a segmentos e a pixel da imagem *Landsat* 8 no norte de Portugal (tabela 11), a classificação orientada a objetos apresentou desempenhos relativamente mais elevados do que os outros tipos de classificadores, com uma exatidão global de 61% (10 classes) e 56% (14 classes), e um índice de concordância *Kappa* de 0,46 (14 classes) e 0,50 (10 classes), que de acordo Landis e Koch (1977), é uma classificação boa


Resultados das matrizes de confusão						
Número de classes	Objetos		Segmentos		Pixel a Pixel	
	10	14	10	14	10	14
Desempenho geral (%)	61	56	52	45	57	49
Índice de concordância <i>Kappa</i>	0,50	0,46	0,39	0,34	0,45	0,40

Tabela 11: Resultados das matrizes de confusão para 10 e 14 classes.






Classificação orientada a objetos



Classificação orientada a segmentos



Classificação orientada a pixel



Carta de ocupação do solo 2007

**Nomenclatura COS 2007**

<span style="color: red;">■</span> Tecido urbano	<span style="color: gray;">■</span> Áreas de extração de inertes, áreas de deposição de resíduos e estaleiros de construção
<span style="color: purple;">■</span> Indústria, comércio e transportes	<span style="color: brown;">■</span> Espaços verdes urbanos, equipamentos desportivos, culturais e de lazer, e zonas históricas



Figura 23: Comparação dos territórios artificializados dos três classificadores com a COS 2007.

Na classe de nível 1 dos *território artificializados* (1), que inclui as classes de nível 2, *tecido urbano* (1.1); *indústria, comércio e transportes* (1.2); *áreas de extração de inertes, áreas de deposição de resíduos e estaleiros de construção* (1.3); *espaços verdes urbanos, equipamentos desportivos, culturais e de lazer e zonas históricas* (1.4). Podemos observar pelas tabelas 12, 13 e 14, que a classificação orientada a objetos apresenta um melhor desempenho. Na classificação orientada a objetos o *tecido urbano* (1.1) apresenta erros de omissão de 52,28%, ou seja, uma exatidão do produtor de 47,72% e um erro de comissão de 44,10%, e uma exatidão de utilizador de 55,90%. O *tecido urbano* (1.1) apresenta uma certa confusão espectral com áreas *agrícolas heterogêneas* (2.4) e *Florestas* (3.1). A confusão espectral com as *áreas agrícolas heterogêneas* (2.4), deve-se a existirem a pequenos pixéis que representam áreas edificadas próximos a áreas agrícolas, o que resulta na confusão espectral entre as duas classes. Já as *Florestas* (3.1) resulta da existência de vegetação aglutinadas junto ao *tecido urbano* (1.1). A classificação orientada a segmentos e a pixel apresentam erros de omissão e comissão elevados, 88,86%, 52,98% e 65,61%, 31,03%, respetivamente.

Na classe *indústria, comércio e transportes* (1.2) foi novamente a classificação orientada a objetos que apresentou um melhor desempenho, com uma exatidão de produtor de 47,09% e uma exatidão de utilizador de 46,65%, enquanto a classificação orientada a segmentos e pixel apresentaram resultados insatisfatórios, como podemos observar nas tabelas 12, 13 e 14. Esta classe mostrou-se difícil de separar do *tecido urbano* (1.1) nos três classificadores, devido a apresentar níveis de refletância espectral semelhantes, o que causa uma elevada confusão espectral. Também ocorre alguma confusão espectral com as áreas agrícolas que se encontrem em pousio.

Nas *áreas de extração de inertes, áreas de deposição de resíduos e estaleiros de construção* (1.3) demonstrou-se uma classe difícil de classificar. Dos três classificadores, foi a classificação orientada a objetos que apresentou melhores resultados, com uma exatidão de produtor de 38,23% e uma exatidão de utilizador de 55,42%, comparando com a classificação orientada a segmentos e pixel que registaram resultados muito insatisfatórios, pelo que podemos observar nas tabelas 13 e 14. A classificação orientada a objetos através do *eCognition* provou-se vantajosa nesta classe devido à construção de regras de classificação, que permitiu uma maior versatilidade na classificação. Nos três classificadores existiu uma elevada confusão espectral com o *tecido urbano* (1.1) e *indústria, comércio e transportes* (1.2).

Os *espaços verdes urbanos, equipamentos desportivos, culturais e de lazer e zonas históricas* (1.4) foi uma das classes mais difíceis de classificar, isso deve-se à nomenclatura da carta de ocupação do solo de 2007, por agregar várias classes, com uma assinatura espectral muito diferente, ou seja, integra, campos de golfe, instalações desportivas, parques de campismo, equipamentos culturais, de lazer e zonas históricas, ou seja, é uma classe muito heterogénea, o que levou a que na altura da classificação, esta classe ficasse incluída em outra classes de nível 2. Dos três classificadores foi a classificação orientada a objetos que apresentou melhor resultado, como podemos observar na tabela 12, 13 e 14. Na classificação orientada a objetos existiu uma elevada confusão espectral com o *tecido urbano* (1.1), já na classificação orientada a segmentos foi com as áreas agrícolas heterogéneas, na classificação orientada a pixel a confusão espectral ocorreu com o *tecido urbano* (1.1) e a *indústria, comércio e transportes* (1.2). Devido a esta classe apresentar desempenhos muito baixos, ela foi eliminada e posteriormente incluída no tecido urbano de modo a produzir uma nova classificação de 10 classes, com isso houve um ligeiro aumento do desempenho das classes dos *territórios artificializados* (1.).

Classificação orientada a objetos (14 Classes) – COS 2007				
Classes	Erro de omissão (%)	Exatidão do produtor (%)	Erro de comissão (%)	Exatidão do utilizador (%)
1.1	52.28	47.72	44.10	55.90
1.2	52.91	47.09	53.35	46.65
1.3	61.77	38.23	44.58	55.42
1.4	71.02	28.98	70.11	29.89
2.1	70.20	29.80	64.81	35.19
2.2	45.38	54.62	47.87	52.13
2.3	68.32	31.68	56.35	43.65
2.4	80.34	19.66	77.71	22.29
3.1	46.55	53.45	55.82	44.18
3.2	45.42	54.58	44.23	55.77
3.3	68.41	31.59	51.53	48.47
4.2	39.68	60.32	21.42	78.58
5.1	25.91	74.09	12.52	87.48
5.2	0.22	99.78	0.08	99.92

Tabela 12: Cálculos de erro de omissão, comissão, exatidão do produtor e utilizador para a classificação orientada objetos (14 classes) – COS 2007.

Classificação orientada a segmentos (14 classes) – COS 2007				
Classes	Erro de omissão (%)	Exatidão do produtor (%)	Erro de comissão (%)	Exatidão do utilizador (%)
1.1	88.86	11.14	52.98	47.02
1.2	61.89	38.11	79.26	20.74
1.3	95.22	4.78	83.56	16.44
1.4	95.64	4.36	99.40	0.60
2.1	91.80	8.20	74.79	25.21
2.2	39.14	60.86	75.42	24.58
2.3	99.17	0.83	99.97	0.03
2.4	83.03	16.97	86.47	13.53
3.1	75.68	24.32	54.51	45.49
3.2	46.19	53.81	51.63	48.37
3.3	83.41	16.59	79.53	20.47
4.2	88.74	11.26	89.23	10.77
5.1	32.22	67.78	19.69	80.31
5.2	0.71	99.29	0.34	99.66

Tabela 13: Cálculos de erro de omissão, comissão, exatidão do produtor e utilizador para a classificação orientada a segmentos (14 classes) – COS 2007.

Classificação orientada a pixel (14 classes) – COS 2007				
Classes	Erro de omissão (%)	Exatidão do produtor (%)	Erro de comissão (%)	Exatidão do utilizador (%)
1.1	65.61	34.39	31.03	68.97
1.2	69.83	30.17	93.43	6.57
1.3	99.94	0.06	90.03	9.97
1.4	99.19	0.81	95.23	4.77
2.1	70.15	29.85	73.49	26.51
2.2	40.04	59.96	69.35	30.65
2.3	91.46	8.54	99.90	0.10
2.4	93.45	6.55	88.34	11.66
3.1	51.08	48.92	37.49	62.51
3.2	58.02	41.98	46.24	53.76
3.3	82.81	17.19	65.28	34.72
4.2	99.94	0.06	99.96	0.04
5.1	39.67	60.33	15.48	84.52
5.2	2.78	97.22	0.00	100.00

Tabela 14: Cálculos de erro de omissão, comissão, exatidão do produtor e utilizador para a classificação orientada a pixel (14 classes) – COS 2007.



As quatro classes relativas às *áreas agrícolas e agro-florestais* do nível 1, foram as que apresentaram piores resultados nas três classificações a nível de exatidão de produtor e utilizador, como se pode observar na tabela 12, 13 e 14. As principais razões para estes resultados, são as assinaturas espectrais muito semelhantes para os quatro tipos de classes agrícolas. Outra razão é a carta de ocupação do solo de 2007 não ser uma verdade absoluta do terreno, podendo por vezes apresentar classificações erradas, principalmente quando os tipos de solo são muito semelhantes. A diferença de escala de trabalho, ou seja, a classificação através de interpretação visual da carta de ocupação do solo de 2007 possui uma unidade mínima cartográfica de 1 hectare, as classificações produzidas através de *software* de deteção remota, tem uma resolução espacial de 15 metros, o que traz mais detalhe. E por ultimo, um problema clássico da classificação de imagens, que é a confusão espectral entre áreas agrícolas e áreas florestais.

No global das classes agrícolas nos três classificadores, o classificador que apresentou melhores resultados foi a classificação orientada a objetos, onde a versatilidade das regras de classificação provou ser uma mais valia.

Fazendo a análise das classes agrícolas, a classe que apresentou melhor desempenho foi as *culturas permanentes* (2.2), especialmente na classificação orientada a objetos, onde alcançou uma exatidão do produtor de 54,62% e uma exatidão do utilizador de 52.13%. A classificação orientada a segmentos e a pixel igualmente apresentaram resultados interessantes, como podemos observar pela tabela 12, 13 e 14.

Ao comparar as tabelas 12, 13 e 14 das quatro classes relativas às classes agrícolas e agro-florestais, podemos concluir que é na classificação orientada a objetos que apresenta melhores resultados, em comparação com a classificação orientada a segmentos e pixel para as *culturas temporárias* (2.1), *pastagens permanentes* (2.3) e *áreas agrícolas heterogéneas* (2.4). A classe que apresenta pior resultado na classificação a objetos foi as *áreas agrícolas heterogéneas* (2.4), devido a ser uma classe de ocupação do solo muito heterogénea e de difícil classificação, por apresentar vários tipos de solo, ou seja, é uma classe de ocupação do solo que inclui no nível 3, *culturas temporárias e/ou pastagens associadas a culturas permanentes; Sistemas culturais e parcelares complexos; agricultura com espaços naturais e semi-naturais; sistemas agro-florestais*; tornando-se mais complexa no nível 4 e 5, o que nos leva a crer que a quando da interpretação visual da imagem da carta de ocupação do solo, quando o técnico esta em dúvida do tipo de solo agrícola, ele incorpora essa classe nas áreas agrícolas heterogéneas, o que explica o fraco desempenho na classificação orientada a objetos.

Um dos principais motivos para a realização dos resultados de classificação com 10 classes, foi a união em apenas a classe de nível 1 de todas as classes agrícolas, de modo a aumentar o desempenho dos resultados de desempenho geral, índice de concordância *Kappa*, exatidão do produtor e do utilizador. Como podemos observar pela tabela 11, houve um ligeiro aumento desempenho geral e do índice *kappa*, devido à união das classes agrícolas, já nas tabelas da exatidão do produtor e do utilizador também ocorreu o aumento do desempenho dos resultados, como podemos observar nas tabelas 15, 16 e 17, com a classificação orientada a objetos a produzir melhores resultados. De referir que para o resultado de 14 classes e 10 classes, nos três classificadores houve uma elevada confusão espectral com as áreas florestais e outros tipos de solos agrícolas. Na figura 24, podemos observar a comparação entres os três classificadores e a carta de ocupação do solo de 2007 para a classes agrícolas.

Classificação orientada a objetos (10 classes) – COS 2007				
Classes	Erro de omissão (%)	Exatidão do produtor (%)	Erro de comissão (%)	Exatidão do utilizador (%)
1.1	51.43	48.56	43.28	56.71
1.2	52.90	47.09	53.34	46.65
1.3	61.76	38.23	44.57	55.42
2	44.42	55.57	40.07	59.92
3.1	46.54	53.45	55.81	44.18
3.2	45.41	54.58	44.22	55.77
3.3	68.40	31.59	51.52	48.47
4.1	39.67	60.32	21.41	78.58
5.1	25.90	74.09	12.51	87.48
5.2	0.21	99.78	0.07	99.92


Tabela 15: Cálculos de erro de omissão, comissão, exatidão do produtor e utilizador para a classificação orientada a objetos (10 classes) – COS 2007.

Classificação orientada a pixel (10 classes) – COS 2007				
Classes	Erro de omissão (%)	Exatidão do produtor (%)	Erro de comissão (%)	Exatidão do utilizador (%)
1.1	65.77	34.23	30.34	69.66
1.2	69.83	30.17	93.43	6.57
1.3	99.94	0.06	90.03	9.97
2	33.73	66.27	56.58	43.42
3.1	51.08	48.92	37.49	62.51
3.2	58.02	41.98	46.24	53.76
3.3	82.81	17.19	65.28	34.72
4.2	99.94	0.06	99.96	0.04
5.1	39.67	60.33	15.48	84.52
5.2	2.78	97.22	0.00	100.00


Tabela 16: Cálculos de erro de omissão, comissão, exatidão do produtor e utilizador para a classificação orientada a pixel (10 classes) – COS 2007.

Classificação orientada a segmentos (10 classes) – COS 2007				
Classes	Erro de omissão (%)	Exatidão do produtor (%)	Erro de comissão (%)	Exatidão do utilizador (%)
1.1	87.38	12.62	67.73	32.27
1.2	62.94	37.06	79.77	20.23
1.3	95.31	4.69	83.84	16.16
2	40.24	59.76	57.66	42.34
3.1	76.02	23.98	54.99	45.01
3.2	46.64	53.36	51.87	48.13
3.3	83.47	16.53	79.59	20.41
4.2	89.17	10.83	89.51	10.49
5.1	33.06	66.94	20.16	79.84
5.2	1.14	98.86	0.34	99.66

Tabela 17: Cálculos de erro de omissão, comissão, exatidão do produtor e utilizador para a classificação orientada segmentos (10 classes) – COS 2007.




Classificação orientada a objetos



Classificação orientada a segmentos



Classificação orientada a pixel



Carta de ocupação do solo 2007

**Nomenclatura COS 2007**


	Culturas temporárias		Pastagens permanentes
	Culturas permanentes		Áreas agrícolas heterogêneas




Figura 24: Comparação das áreas agrícolas e agro-florestais dos três classificadores com a COS 2007.



No que diz respeito às classes florestais, o classificador que apresentou resultados com o melhor desempenho foi a classificação orientada a objetos. Podemos observar através das tabelas 12, 13 e 14, que na classificação orientada a objetos a classe com melhor desempenho foi as *florestas abertas e vegetação arbustiva e herbácea* (3.2), com uma exatidão de produtor de 54,58% e uma exatidão de utilizador de 55,77%. A classe que apresentou pior desempenho foi as zonas descobertas e com pouca vegetação, com uma exatidão de produtor de 31,59% e 48,47%. O classificador que apresentou o pior desempenho foi a classificação orientada a segmentos.

Esses resultados podem ser explicados pela incerteza da carta de ocupação do solo apresenta e pela unidade mínima cartográfica de 1ha, ou seja, após uma interpretação visual da imagem *Landsat 8* e uma análise do resultado da classificação orientada a objetos podemos concluir que para certas áreas, a classificação orientada a objetos aproxima-se mais da realidade do terreno do que a carta de ocupação do solo, como podemos observar na figura 25. Igualmente na figura 25, que mostra a comparação entre a classificação orientada a objetos e a carta de ocupação do solo, usando os valores do índice de vegetação por diferença normalizada (NDVI) e das regras de classificação foi possível separar a classe das *florestas* (3.1) e das *florestas abertas e vegetação arbustiva e herbácea* (3.2), melhorando os resultados em relação à classificação orientada a segmentos e a pixel.

De referir que a existência de uma elevada confusão espectral entre a classe de *florestas* (3.1) e *florestas abertas e vegetação arbustiva e herbácea* (3.2) e entre as *zonas descobertas e com pouca vegetação e florestas abertas e vegetação arbustiva e herbácea* (3.3).




Classificação orientada a objetos



Classificação orientada a segmentos



Classificação orientada a pixel



Carta de ocupação do solo 2007

**Nomenclatura COS 2007**

- Florestas
- Florestas abertas, vegetação arbustiva e herbácea
- Zonas descobertas e com pouca vegetação




Figura 25: Comparação das florestas, meios naturais e semi-naturais dos três classificadores com a COS 2007.

De seguida temos as classes das *zonas húmidas* (4), que inclui as *zonas húmidas interiores* (4.1) e as *zonas húmidas litorais* (4.2).


Podemos observar nas tabelas 12, 13 e 14, que a classificação orientada a objetos produziu bons resultados, tendo sido o classificador com melhor desempenho, com uma exatidão de produtor de 60,32% e uma exatidão de utilizador de 78,58%. Enquanto os classificadores orientados a segmentos e a pixel registaram desempenhos insatisfatórios, devido a ser uma classe que produz elevada confusão espectral com classes as florestais.

As *zonas húmidas litorais* (4.2) foram retiradas da classificação final com o objetivo de aumentar o desempenho geral e o índice de concordância *Kappa*, visto que na carta de ocupação do solo não tinham relevância, constituído por apenas dois elementos, o que era de difícil classificação.







Classificação orientada a objetos



Classificação orientada a segmentos



Classificação orientada a pixel



Carta de ocupação do solo 2007

**Nomenclatura COS 2007**  
 Zonas húmidas litorais

0 4 km



Figura 26: Comparação das zonas húmidas dos três classificadores com a COS 2007.

Os *corpos de água* (5) incluem as *águas interiores* (5.1) e as *águas marinhas e costeiras* (5.2). Sendo uma classe de fácil classificação, bastando apenas usar a banda do infravermelho próximo e otimizar os seus valores de modo a classificar só os corpos de água. Todos os classificadores produziram resultados elevados, com o classificador orientado a objetos a destacar-se com uma ligeira diferença de resultados. Isso deveu-se ao *software eCognition* (9.0) permitir usar a banda do infravermelho próximo com formas geométricas, nesta caso usou-se o comprimento, de modo a classificar os rios, nas águas marinhas e costeiras usou-se a área, fazendo a distinção clara entre os corpos de água águas interiores e as águas marinhas e costeiras. A classificação orientada a objetos atingiu uma exatidão de produtor de 74,09% e uma exatidão de utilizador de 87,48%. Para os corpos de água interiores. Para as águas marinhas e costeiras alcançou-se uma exatidão de produtor de 99,78% e uma exatidão de utilizador de 99,92%.



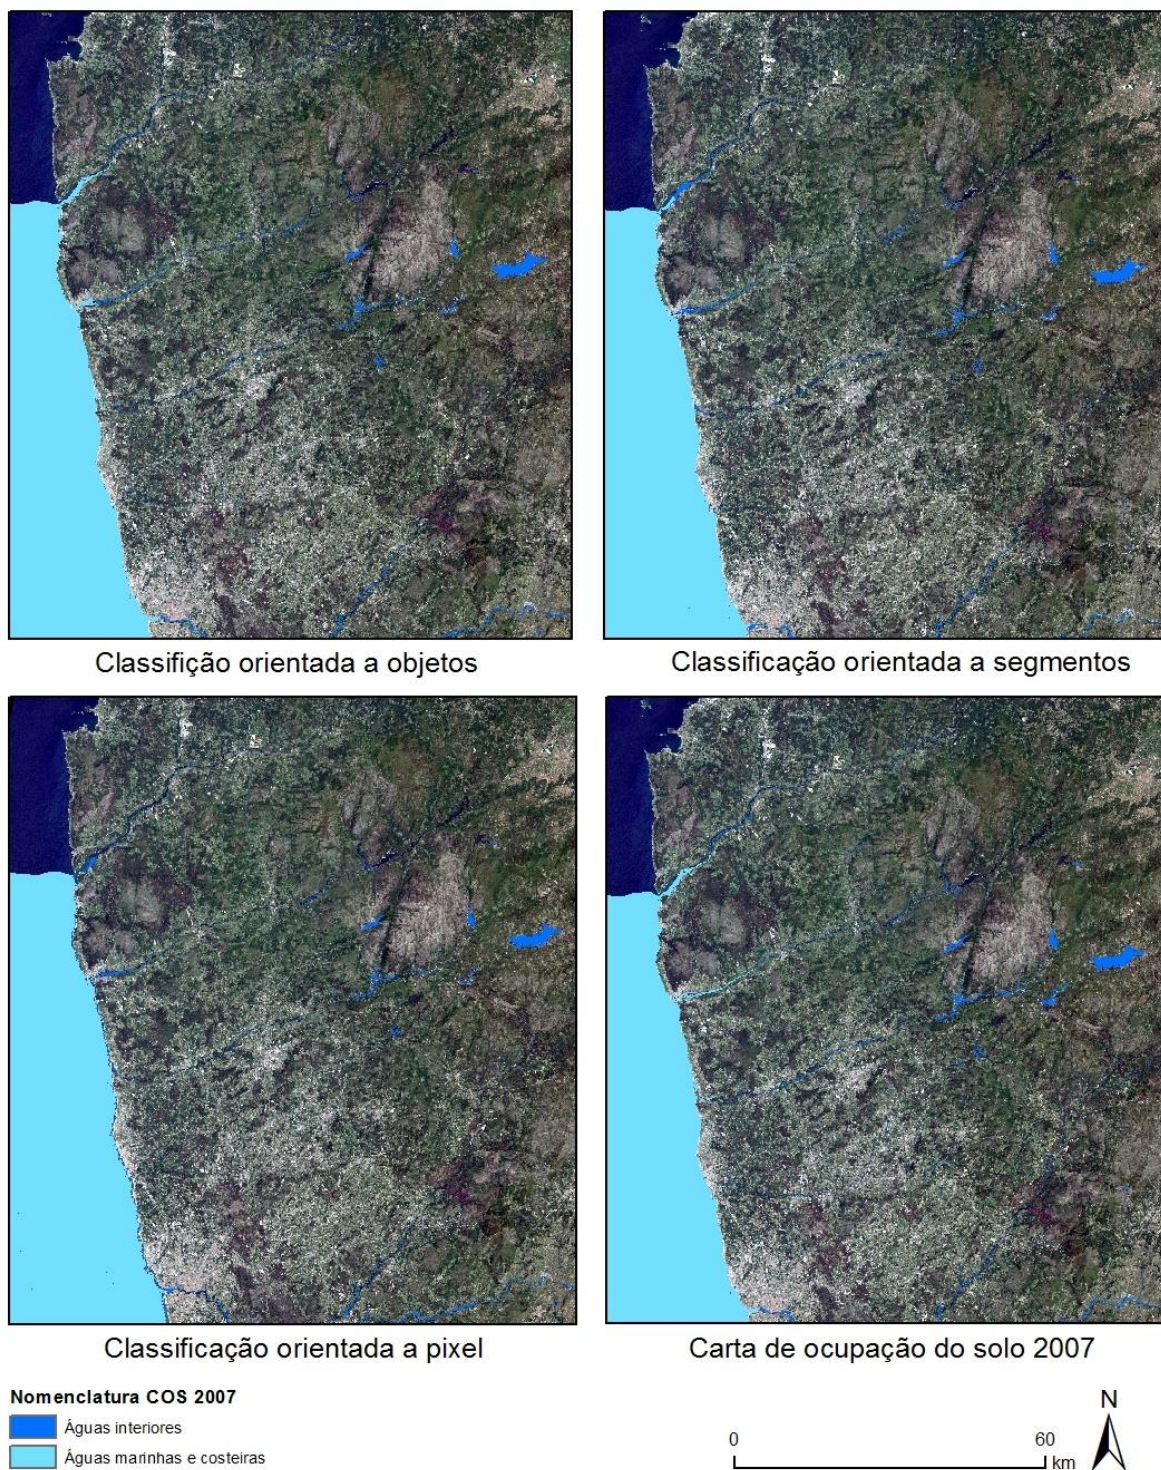


Figura 27: Comparação dos corpos de água dos três classificadores com a COS 2007.

A classificação orientada a objetos provou ser mais rigorosa comparativamente com a classificação orientada a segmentos e à classificação orientada a pixéis. Contudo, a carta de ocupação do solo de 2007 provou uma elevada incerteza temática, principalmente nas classes de *áreas agrícolas e agro-florestais* (2) e *florestas* (3).



De modo a responder a este problema, procedeu-se à elaboração de uma nova carta de ocupação do solo, através de ortofotomapas de 2014, disponibilizados na plataforma *ArcGis online*. Os ortofotomapas possuem 1 metro de resolução espacial e são adquiridos através dos satélites *GeoEye* e *IKONOS*.

A figura 28 mostra a carta de ocupação do solo de 2015 para uma determinada área do norte de Portugal continental. Foi escolhida esta localização devido a ser a única área onde se encontravam as 14 classes de ocupação do solo.

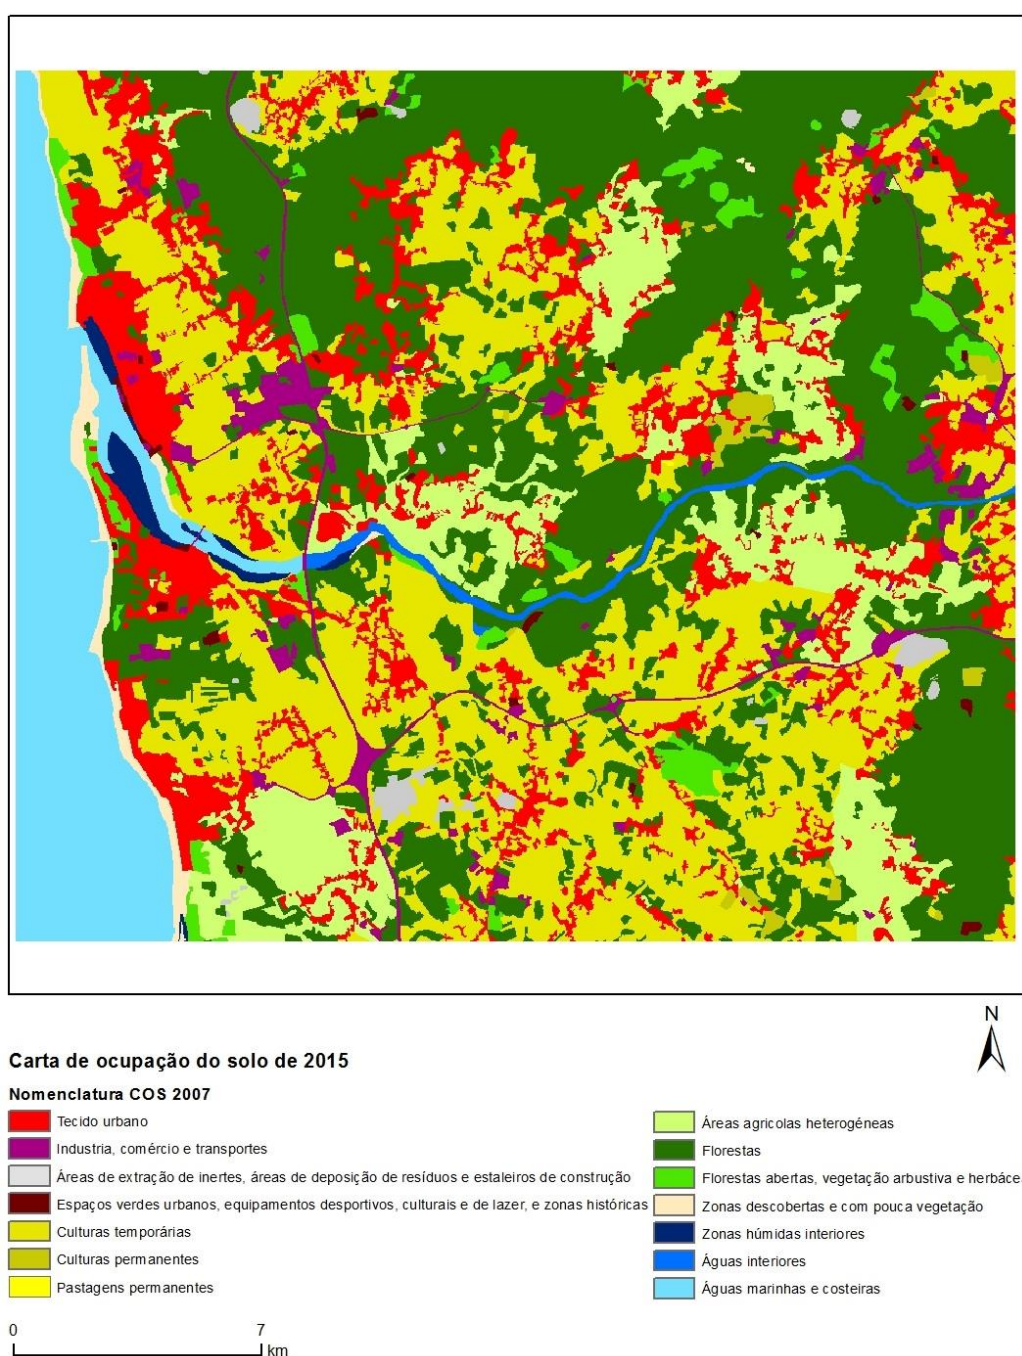


Figura 28: Carta de ocupação do solo de 2015.

O principal objetivo para a elaboração de uma nova carta de ocupação do solo, era descobrir se as diferenças que existiam entre a classificação orientada a objetos e a carta de ocupação do solo de 2007 tinham uma razão temporal ou a incerteza temática da COS 2007.

Na figura 29, podemos observar a comparação entre a classificação orientada a objetos e a carta de ocupação do solo de 2007 e 2015

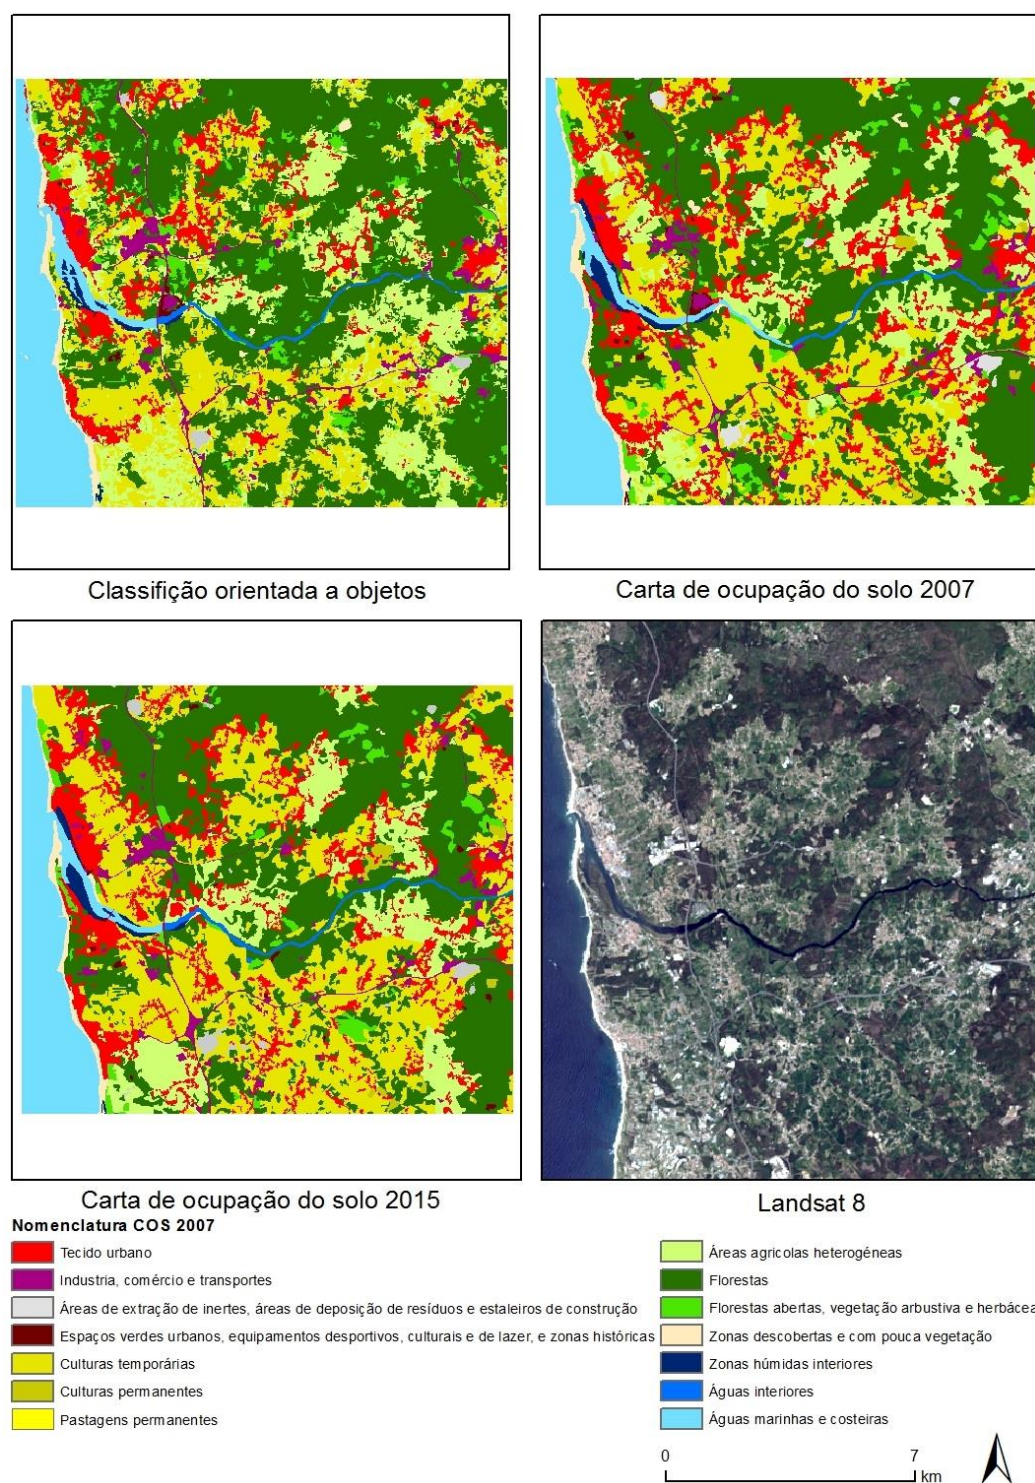


Figura 29: Comparação da classificação orientada a objetos com a COS 2007 e 2015.




Para o efeito de comparação foi elaborada a exatidão global e o índice de concordância *Kappa*, tal como os cálculos de erro de comissão, omissão, exatidão do produtor e utilizador.

Resultados das matrizes de confusão		
	Objetos – COS 2007	Objetos – COS 2015
Desempenho geral (%)	59	60
Índice de concordância <i>Kappa</i>	0,47	0,48

Tabela 18: Resultado da matriz de confusão para a classificação orientada a objetos e a COS 2007 e 2015.

Como podemos observar pela tabela 18, a diferença entre os dois resultados da matriz de confusão não mostrou a existência de uma grande diferença, apenas registou uma diferença de 1% de desempenho geral entre as duas comparações.

Nos *territórios artificializados* (1) a comparação entre a classificação orientada a objetos e a COS 2007 apresenta resultados relativamente semelhantes à comparação com a COS 2015, expeto a classe dos *espaços verdes urbanos, equipamentos desportivos, culturais e de lazer, e zonas históricas* (1.4), apresentado um desempenho mais elevado na comparação à COS 2007, isso explica-se devido à não estar corretamente representada na COS 2007, na figura 30 podemos observar elementos presentes no terreno e corretamente assinalados na COS 2015, não estando cartografados na COS 2007.






Figura 30: Comparação da classe *espaços verdes urbanos, equipamentos desportivos, culturais e de lazer, e zonas históricas* (1.4), entre a COS 2007 e 2015.

No que diz respeito às *áreas agrícolas e agro-florestais* (2), a principal causa de confusão espectral foi entre as *culturas temporárias* (2.1) e as *áreas agrícolas heterogêneas* (2.4), ambos os tipos de ocupação do solo são idênticos, não se percebendo qual o tipo de ocupação de solo agrícola. E como foi dito anteriormente, as áreas agrícolas heterogêneas incluem no nível 3; culturas temporárias de sequeiro associadas a culturas permanentes; Culturas temporárias de regadio associadas a culturas permanentes; Pastagens associadas a culturas permanentes; Sistemas culturais e parcelares complexos; Sistemas culturais e parcelares complexos; Agricultura com espaços naturais e semi-naturais; Sistema agro-florestal (SAF) com culturas temporárias de sequeiro; SAF com culturas temporárias de regadio; SAF com pastagens; SAF com culturas permanentes. Tornando-se classes mais complexas no nível 5. Devido a esse elevado grau de heterogeneidade, torna-se difícil a atingir uma boa separabilidade espectral com as *culturas temporárias* (2.1) que também incluem, culturas temporárias de sequeiro e culturas temporárias de regadio. De referir as *culturas permanentes* (2.2), a apresentarem resultados de erro de omissão e comissão de 100% na COS 2015 e na COS 2007 perto dos 100%, isso deve-se a ser difícil de existir poucos elementos desta classe no ortofotomapas e de ser difícil separar essa classe das

restantes áreas agrícolas. Na figura 31 podemos observar a dificuldade em diferenciar as duas classes.

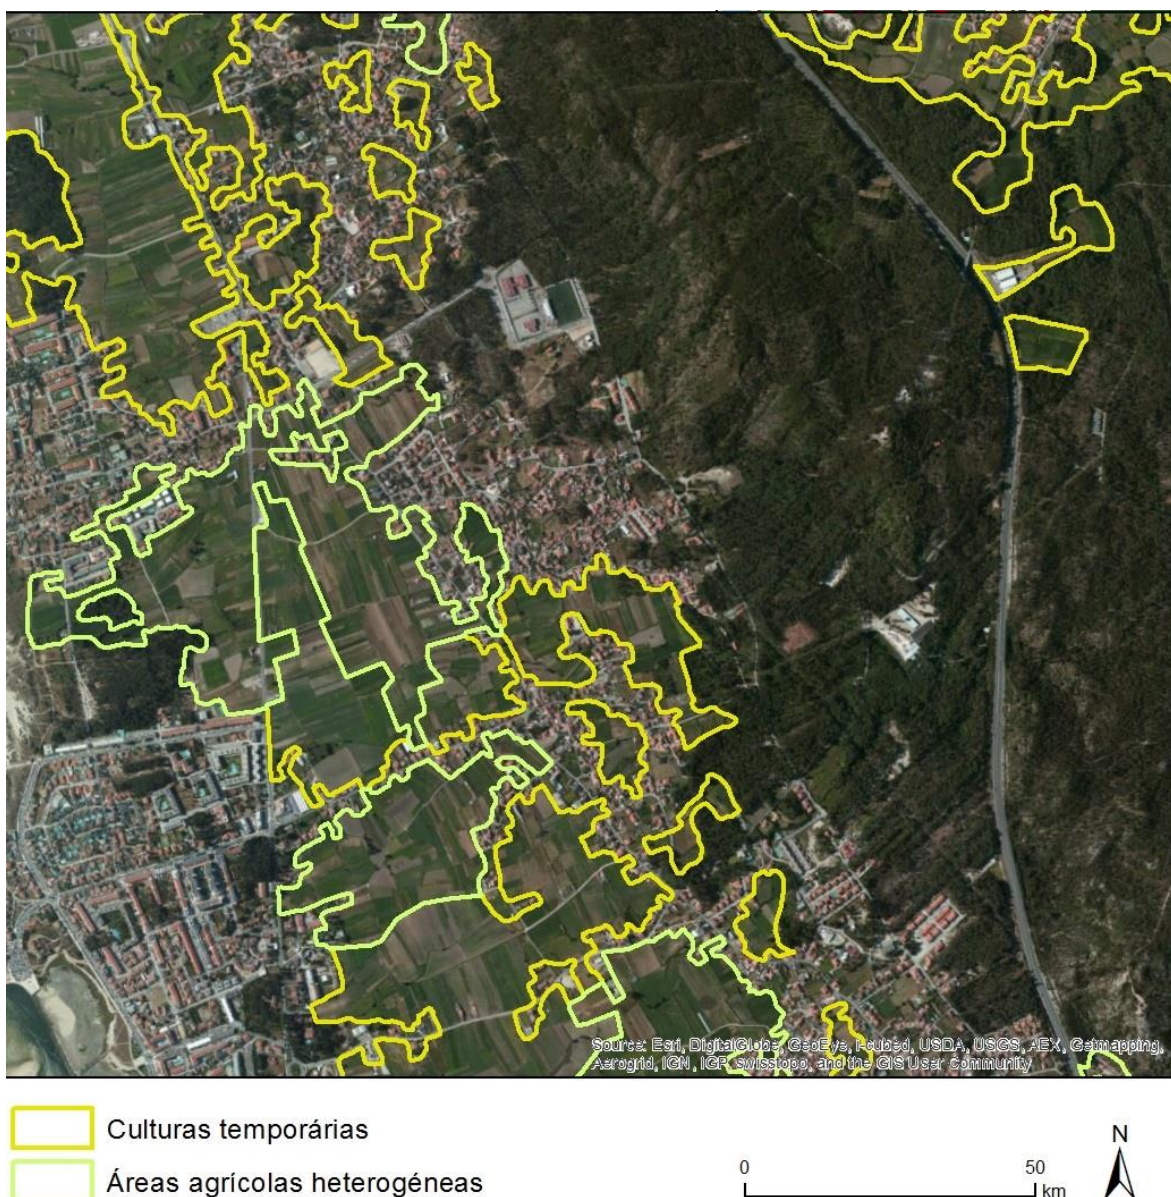


Figura 31: Comparação das *culturas temporárias* (2.1) e *áreas agrícolas heterogêneas* (2.4) na COS 2015.

No que diz respeito à classe das *Florestas* do nível 1, apresentaram resultados relativamente semelhantes na classe das *florestas* (3.1), nas *florestas abertas e vegetação arbustiva e herbácea* (3.2), a COS 2015 apresentou resultados baixos, no entanto, apresentou resultados melhores que os da COS 2007. Os resultados para as *florestas abertas e vegetação arbustiva e herbácea* (3.2) pode ser explicado pela diferença temporal das duas imagens utilizadas, a diferença de 8 anos entre a COS 2007 e a COS 2015 pode fazer com que haja modificações nos solos, principalmente nas classes florestais, visto



estarem mais sujeitas às condições meteorológicas, como é o caso dos incêndios. Na figura 31 temos um exemplo em como um elemento na COS 2007 é assinalada como floresta e no ortofotomapa é claramente uma *floresta aberta e vegetação arbustiva e herbácea* (3.2), Não tendo acesso aos ortofotomapas da COS 2007 para efetuar essa comparação, também pode sugerir um erro técnico. Nas *zonas descobertas e com pouca vegetação* (3.3), a COS 2007 e 2015 apresentam desempenhos semelhantes.

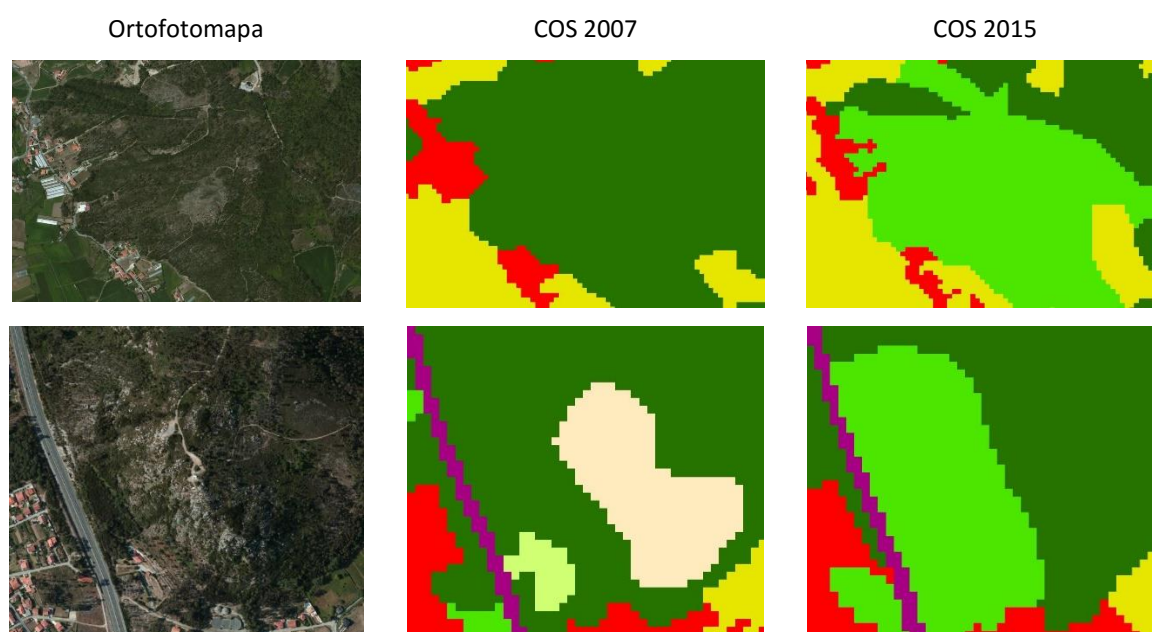


Figura 32: Comparação das florestas, meios naturais e semi-naturais entre a COS 2007 e COS 2015.

No que diz respeito às *zonas húmidas litorais* (4.2), a exatidão do produtor e do utilizador apresentou resultados relativamente melhores para classificação orientada a objetos - COS 2007 a apresentar uma diferença de 2% em relação à classificação orientada a objetos – COS 2015, como podemos observar pela tabela 19 e 20.

Os *corpos de água* (5) registaram melhor desempenho na comparação para a classificação orientada a objetos com a COS 2015, principalmente nas *águas interiores* (5.1). Isso deveu-se à existência de um corpo de água com uma dimensão de 4 hectares não classificado na COS 2007 e classificado na classificação orientada a objetos, posteriormente assinalado na COS 2015. Outra diferença da COS 2007 para a COS 2015 que aumentou o desempenho da comparação entre a classificação orientada a objetos e a

COS 2015 foi o aumento do comprimento do rio Cávado a começar da autoestrada nº 28 em relação à COS 2007, como podemos observar pela figura 33.

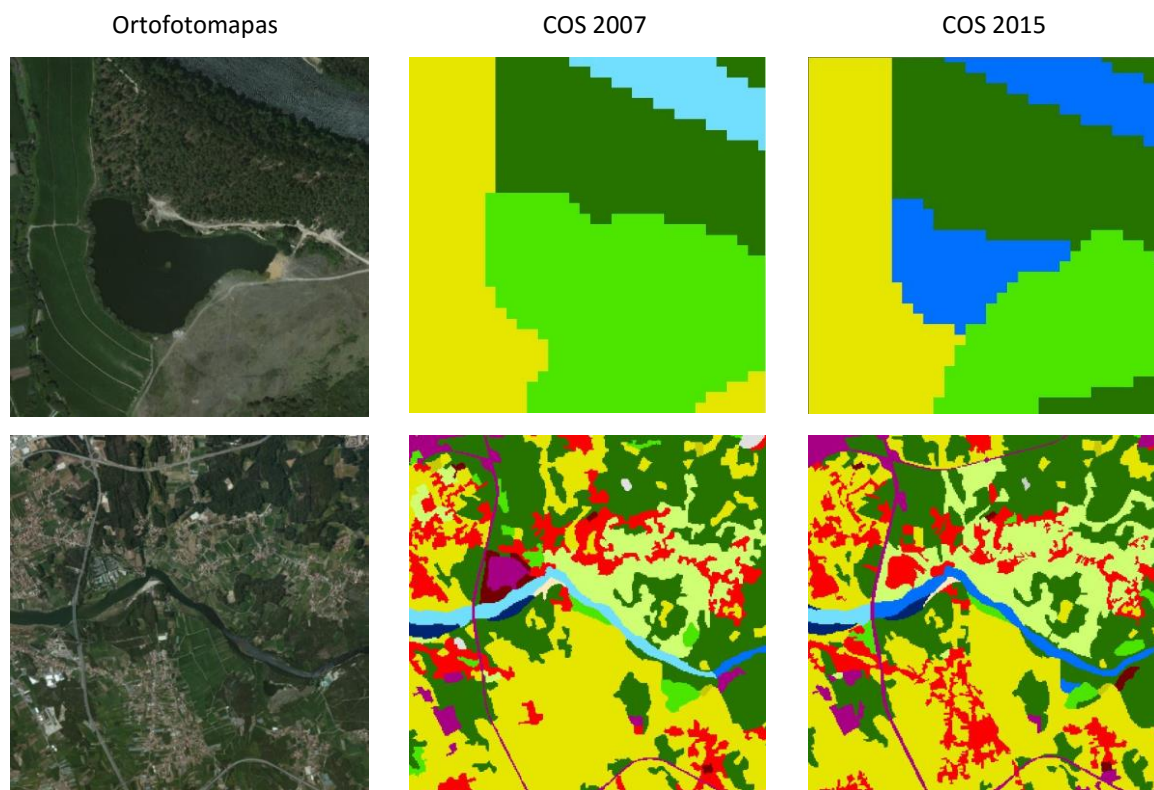


Figura 33: Comparação dos corpos de água entre a COS 2007 e 2015.

Classificação orientada a objetos - COS 2007

Classes	Erro de omissão (%)	Exatidão do produtor (%)	Erro de comissão (%)	Exatidão do utilizador (%)
1.1	56.95	43.05	28.61	71.39
1.2	38.32	61.68	49.67	50.33
1.3	59.62	40.38	13.89	86.11
1.4	68.12	31.88	65.90	34.10
2.1	54.86	45.14	50.25	49.75
2.2	99.89	0.11	99.29	0.71
2.3	43.10	56.90	75.19	24.81
2.4	56.15	43.85	61.72	38.28
3.1	25.23	74.77	35.24	64.76
3.2	93.51	6.49	95.19	4.81
3.3	36.36	63.64	35.66	64.34
4.2	55.42	44.58	22.96	77.04
5.1	25.80	74.20	48.16	51.84
5.2	4.11	95.89	4.29	95.71

Tabela 19: Cálculos de erro de omissão, comissão, exatidão do produtor e utilizador para a classificação orientada a objetos e COS 2007.

Classificação orientada a objetos - COS 2015

Classes	Erro de omissão (%)	Exatidão do produtor (%)	Erro de comissão (%)	Exatidão do utilizador (%)
1.1	55.37	44.63	33.14	66.86
1.2	46.18	53.82	48.06	51.94
1.3	58.17	41.83	16.39	83.61
1.4	90.18	9.82	90.61	9.39
2.1	57.56	42.44	40.55	59.45
2.2	100.00	0.00	100.00	0.00
2.3	55.56	44.44	84.96	15.04
2.4	47.51	52.49	64.97	35.03
3.1	24.56	75.44	36.65	63.35
3.2	83.87	16.13	89.97	10.03
3.3	23.18	76.82	38.64	61.36
4.2	53.37	46.63	24.81	75.19
5.1	25.95	74.05	16.65	83.35
5.2	1.74	98.26	3.35	96.65

Tabela 20: Cálculos de erro de omissão, comissão, exatidão do produtor e utilizador para a classificação orientada a objetos – COS 2015.

## 6. Considerações finais

O principal objetivo da presente dissertação focou-se no desenvolvimento de cartografia, produzida através da classificação orientada a objetos em dados de baixa resolução espacial e espectral. Posteriormente comparado o classificação orientada a objetos com a classificação orientada pixel a pixel e segmentos, através da exatidão global e índice de concordância *Kappa*.

No desenvolvimento da metodologia, principalmente na construção das regras de classificação das várias classes de ocupação do solo, foram vários os desafios, desde a limitação da resolução espectral e espacial da imagem Landsat 8, a elevada complexidade e heterogeneidade da área geográfica, o elevado número de classes de ocupação do solo compreendidas na carta de uso e ocupação do solo para Portugal continental de 2007, classes com características espectrais muito semelhantes entre si, sendo difíceis atingir uma boa separabilidade espectral, e o desconhecimento da área de estudo por parte do utilizador.

Um dos principais problemas na criação das regras de classificação foi na extração das quatro classes incluídas nas *áreas agrícolas e agro-florestais* (2). Mesmo visualmente, estas classes apresentam-se muito difíceis de distinguir, o que se pode concluir, que mesmo a COS 2007, apresenta uma elevada incerteza temática na classificação das *áreas agrícolas e agro-florestais*. Outro desafio, foi a classificação dos *Espaços verdes urbanos, equipamentos desportivos, culturais e de lazer, e zonas históricas* (1.4), visto que inclui várias ocupações do solo com assinaturas espectrais muito diferentes. De modo a responder a estes desafios, produziu-se uma nova cartografia, agrupou-se as quatro classes de *áreas agrícolas e agro-florestais* (2) em apenas uma classe, e agrupou-se os *Espaços verdes urbanos, equipamentos desportivos, culturais e de lazer, e zonas históricas* (1.4) ao *tecido urbano* (1.1), de modo a aumentar os valores exatidão global e o índice de concordância *Kappa*.

De modo a resolver a incerteza temática da COS 2007 e a diferença temporal entre a cartografia da COS 2007 e da imagem Landsat 8, que é de 2014, resolveu-se contruir uma nova cartografia de ocupação do solo, designada de COS 2015, para o efeito, utilizou-se ortofotomapas de 2015, disponibilizados na plataforma *ArcGis Online*. Posteriormente



realizou-se as análises de exatidão global e índice de concordância *Kappa* entre a classificação orientada a objetos e a COS 2007 e a COS 2015.

Apesar dos problemas mencionados anteriormente, a classificação orientada a objetos foi a que apresentou valores mais elevados de exatidão global e índice de concordância *Kappa*, comparativamente à classificação orientada a pixel e a segmentos. O que se pode concluir que a extração de dados a partir das novas imagens de baixa resolução espectral e espacial (*Landsat 8*) através da abordagem orientada a objetos, provou ser mais rigorosa, atingindo valores interessantes de exatidão global e índice de concordância *Kappa*. Com a conclusão da presente dissertação foi provado, que é possível extrair dados de imagens de baixa resolução espacial e espectral, como é o caso das novas imagens *Landsat 8*, com recurso à abordagem orientada a objetos (GEOBIA). Para o efeito, o eCognition 9.0, provou ser uma ferramenta indispensável no sucesso da abordagem orientada a objetos, visto que possui uma enorme versatilidade na construção das regras de classificação. A extração dos dados baseia-se principalmente na hierarquia entre os objetos em vez de pixéis individuais, utilizados relações representadas em regras “fuzzy”. O eCognition 9.0 possui outra característica importante, que é a possibilidade de importar modelos digitais do terreno, modelos digitais de superfície e dados Lidar. O que leva a concluir que os resultados da abordagem orientada a objetos poderia ter valores mais elevados com a introdução de dados Lida, visto que iria permitir aplicar regras de classificação que permitissem separar a classe das *florestas* (3.1) e *florestas abertas, vegetação arbustiva e herbácea* (3.2), visto que o NDVI não é suficiente para atingir uma boa separabilidade espectral.

Os processamentos de imagem realizados na presente dissertação, podem ser explorados e melhorados no futuro, com o conhecimento mais aprofundado dos algoritmos presentes no *eCognition 9.0*, sobretudo, dos referentes à segmentação de imagem e à criação de regras de classificação para a extração de objetos.

## Bibliografia

Aplin, P.; Smith, G.M., (2008). Advances in Object –Based Image Classification. The International Archives of the Photogrammetry. Remote Sensing and Spatial Information Sciences, Vol. XXXVII, Part B7. Beijing 2008.

Aplin, P.; Smith, G. M., (2011). Introduction to object-based landscape analysis. International Journal of Geographical Information Science, 25(6), 869-875.

Atkinson, P. M.; foody, G. M., (2002). Uncertainty in remote sensing and GIS: fundamentals. In, Foody, G.M. and Atkinson, P.M. (eds.) Uncertainty in remote sensing and GIS. Chichester, UK, Wiley & Sons.

Baatz, M.; Schäpe, A. (2000). Multiresolution Segmentation: an optimization approach for high quality multi-scale image segmentation.

Blaschke, T., (2013). Object based image analysis: a new paradigm in remote sensing?. ASPRS 2013 Annual Conference, Baltimore, Maryland.

Blaschke, T., (2009). Object based image analysis for remote sensing. Salzburg, Austria, ISPRS Journal of Photogrammetry and Remote Sensing.

Blaschke, T.; Lang, S.; Hay, G. J., (2008). Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications. Berlin, Springer-Verlag, 2008, ISBN: 978-3-540-77057-2.

Blaschke, T.; Strobl, J., (2001). Interfacing Remote Sensing and GIS.

Blaschke, T.; Strobl, J. (2001). What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. GIS, 6, pp. 12-17.

Blaschke, T., (2006). Object based image analysis for automated information Extraction – a synthesis. San Antonio, Texas, MAPPS/ASPRS 2006 Fall Conference.

- Blaschke, T., (2010). Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry & Remote Sensing*. 65, 2-16.
- Blaschke, T., Strobl, J., (2001). What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. *GIS – Zeitschrift für Geoinformations systeme*, 14(6), 12–17.
- Blaschke, T.; Lang. S.; Hay. G., (2008). Object-based image analysis: spatial concepts for knowledge-driven remote sensing applications. *Lecture notes in geoinformation and cartography*. Springer-Verlag Berlin Heidelberg e-ISBN: 978-3-540-77058-9.
- Burnett, C.; Blaschke, T., (2003). A multi-scale segmentation/object relationship modelling methodology for landscape analysis. *Ecological Modelling* 168:233-249.
- Campbell. J. P.; Randolph. R. H., (2011). *Introduction to Remote Sensing – Fifth Edition*. The Guilford Press, New York, ISBN 978-1-60918-176-5.
- Clinton. N.; Holt. A.; Yanb. L.; Gong P., (2008). An accuracy assessment measure for object based image segmentation. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. Vol. XXXVII. Part B4. Beijing 2008, pp 1189-1194.
- Congalton, R. G.; Green, K., (1999). *Assessing the Accuracy of Remotely Sensed Data: Principles and Practises – Second Edition*. CRC Press, Taylor & Francis Group.
- Definiens Professional Reference Book., (2006). *Working with 'Regions' - New OBIA dimensions* Munique, Alemanha: Definiens AG.
- Direção Geral do Território., (2010). *Memória descritiva da carta de uso e ocupação do solo de Portugal Continental para 2007*.

- Encarnação, S.; Rocha, J.; Tenedório, J. A.; Estanqueiro, R. (2007). Cartografia de uso do solo em ambiente urbano - análise orientada por objeto de imagens *quickbird*. Finisterra, XLII, 84, 2007, pp. 87-102.
- Landsat 8. Disponível em <http://landsat.usgs.gov/landsat8.php>. Acesso durante o mês de Novembro, Dezembro e Janeiro.
- Lewinski, S. (2006). Applying fused multispectral and panchromatic data of Landsat ETM+ to object oriented classification. Proceedings of the 26th EARSeL Symposium, New Developments and Challenges in Remote Sensing, May 29-June 2, 2006, Warsaw, Poland
- Lillesand, T. M.; Kiefer, R. W., (2000). Remote Sensing and image interpretation. 4th Edition. New York: Kiefer Wiley and sons.
- Lu, D.; Weng, Q., (2007). A survey of image classification methods and techniques for improving classification performance”, International Journal of Remote Sensing, 28:5, 823 – 870.
- Manakos, I., (2001). eCognition and Precision Farming. <http://www.lrz-muenchen.de/~lmm/>. eCognition Application Notes, Vol. 2, No 2, April 2001.
- MacLean, M. G.; Congalton, R. G. (2012). Map accuracy assessment issues when using an object-oriented approach. ASPRS 2012 Annual Conference Sacramento, California.
- Navulur, K., (2007). Multispectral Image Analysis Using the Object-Oriented Paradigm. CRC Press, Boca Raton, FL. 2007, ISBN 1-4200-4306-4.
- Nixon. M. S.; Aguado. A. S., (2002). Feature Extraction and Image Processing. Reino Unido, Butterworth-Heinemann, 2002, ISBN 0-7506-5078-8.

Noção de Paradigma. Thomas Kuhn. Disponível em [http://filosofia.projectos.esffl.pt/T\\_Khun/Paradigmas\\_Khun.pdf](http://filosofia.projectos.esffl.pt/T_Khun/Paradigmas_Khun.pdf). Acesso em 17 de Janeiro de 2015.

Nussbaum, S; Menz, G., (2008). Object-based image analysis and treaty verification. In: New Approaches in Remote Sensing - Applied to Nuclear Facilities in Iran. Berlin, Springer, Heidelberg, 2008, ISBN: 978-1-4020-6960-4.

Radoux, J.; Bogaert, P.; Defourny, P. (2010). Overall accuracy estimation for geographic object-based classification. Accuracy 2010 Symposium, July 20-23, Leicester, UK, pp 17-20.

Saba, F; Valadanouzj, M. J.; Mokhtarzade, M. (2013). The optimization of multi resolution segmentation of remotely sensed data using genetic algorithm. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XL-1/W3, 2013, SMPR 2013. Pp 345-349.

Wong TH, Shattri BM, Mispan MR, Ahmad N, Sulaiman WN (2003) Feature extraction based on object oriented analysis. In: Proceedings of ATC 2003 Conference, 20–21 May 2003, Malaysia.

Wu, Z.; Yi, L.; Zhang, G. (2010). Object-oriented remote sensed image classification accuracy assessment. Accuracy 2010 Symposium, July 20-23, Leicester, UK, pp 269.272.

Gao, Y; Mas, J. F; Niemeyer, I; Marpu, P. R; Palacio, J. L. (2005). Object-based image analysis for mapping land-cover in a forest area.

Zhang, Y. (2004). Understanding image fusion. Photogrammetric Engineering & Remote Sensing. 70, 657-661.

## ÍNDICE DE FIGURAS

Figura 1: Estrutura da dissertação e fluxograma geral de procedimentos.....	6
Figura 2: Processos básicos da classificação supervisionada. Fonte: Lillesand, T. and Kiefer, R. (2000). .....	8
Figura 3: Enquadramento da área de estudo. ....	15
Figura 4: Comparação dos comprimentos de onda entre o Landsat 8 e 7. Fonte: <a href="http://landsat.usgs.gov/L8_band_combos.php">http://landsat.usgs.gov/L8_band_combos.php</a> . ....	17
Figura 5: Carta de uso e ocupação do solo de Portugal Continental para 2007. ....	22
Figura 6: Fluxograma de procedimentos para a classificação orientada a objetos e segmentos. ....	30
Figura 7: Procedimentos efetuados na classificação supervisionada orientada pixel a pixel. ....	31
Figura 8: Procedimentos efetuados nos processos de melhoramento de imagem.....	32
Figura 9: Correção dos pontos de controlo no processo <i>pan sharpening</i> . ....	33
Figura 10: Resultado da fusão das bandas multiespectrais com a banda pancromática.....	34
Figura 11: Resultado do processo de segmentação <i>multiresolution</i> .....	37
Figura 12: Resultados do algoritmo <i>edge extraction lee sigma</i> . ....	41
Figura 13: Resultado da operação aritmética do algoritmo <i>edge extraction lee sigma</i> .....	41
Figura 14: Resultado do algoritmo Gaussian. ....	42
Figura 15: Resultado da classificação orientada a pixel (10 classes).....	49
Figura 16: Resultado da classificação orientada a pixel (14 classes).....	50
Figura 17: Resultado da classificação orientada a segmentos (10 classes).....	51
Figura 18: Resultado da classificação orientada a segmentos (14 classes).....	52
Figura 19: Resultado da classificação orientada a objetos (10 classes). ....	53
Figura 20: Resultado da classificação orientada a objetos (14 classes). ....	54
Figura 21: Comparação entre os vários classificadores com a carta de uso e ocupação do solo de 2007 (14 classes).....	56
Figura 22: Comparação entre os vários classificadores com a carta de uso e ocupação do solo de 2007 (10 classes).....	57
Figura 23: Comparação dos territórios artificializados dos três classificadores com a COS 2007. ....	59



Figura 24: Comparação das áreas agrícolas e agro-florestais dos três classificadores com a COS 2007. ....	66
Figura 25: Comparação das florestas, meios naturais e semi-naturais dos três classificadores com a COS 2007.....	68
Figura 26: Comparação das zonas húmidas dos três classificadores com a COS 2007. ....	70
Figura 27: Comparação dos corpos de água dos três classificadores com a COS 2007. ....	72
Figura 28: Carta de ocupação do solo de 2015. ....	73
Figura 29: Comparação da classificação orientada a objetos com a COS 2007 e 2015.....	74
Figura 30: Comparação da classe <i>espaços verdes urbanos, equipamentos desportivos, culturais e de lazer, e zonas históricas</i> (1.4), entre a COS 2007 e 2015.....	76
Figura 31: Comparação das <i>culturas temporárias</i> (2.1) e <i>áreas agrícolas heterogéneas</i> (2.4) na COS 2015. ....	77
Figura 32: Comparação das florestas, meios naturais e semi-naturais entre a COS 2007 e COS 2015. ....	78
Figura 33: Comparação dos corpos de água entre a COS 2007 e 2015. ....	79

## ÍNDICE DE TABELAS

Tabela 1: Características do satélite <i>Landsat</i> 8. ....	16
Tabela 2: Caraterísticas das bandas Landsat 8. ....	21
Tabela 3: Nomenclatura da carta de uso e ocupação do solo de Portugal continental para 2007. ....	24
Tabela 4: Características da carta de uso e ocupação do solo de Portugal continental para 2007. ....	25
Tabela 5: Classes da carta de uso e ocupação do solo de Portugal Continental para 2007..	29
Tabela 6: Peso das bandas Landsat 8 no processo de segmentação. ....	35
Tabela 7: Critérios utilizados na segmentação. ....	36
Tabela 8: Regras de classificação realizadas para a classes de ocupação do solo da COS 2007. ....	39
Tabela 9: Exemplo matemático da matriz de confusão. Fonte: Congalton e Green (1999) (adaptado). ....	46
Tabela 10: Qualidade da classificação do índice <i>Kappa</i> . ....	47
Tabela 11: Resultados das matrizes de confusão para 10 e 14 classes. ....	58
Tabela 12: Cálculos de erro de omissão, comissão, exatidão do produtor e utilizador para a classificação orientada objetos (14 classes) – COS 2007. ....	61
Tabela 13: Cálculos de erro de omissão, comissão, exatidão do produtor e utilizador para a classificação orientada a segmentos (14 classes) – COS 2007. ....	62
Tabela 14: Cálculos de erro de omissão, comissão, exatidão do produtor e utilizador para a classificação orientada a pixel (14 classes) – COS 2007. ....	62
Tabela 15: Cálculos de erro de omissão, comissão, exatidão do produtor e utilizador para a classificação orientada a objetos (10 classes) – COS 2007. ....	64
Tabela 16: Cálculos de erro de omissão, comissão, exatidão do produtor e utilizador para a classificação orientada a pixel (10 classes) – COS 2007. ....	65
Tabela 17: Cálculos de erro de omissão, comissão, exatidão do produtor e utilizador para a classificação orientada segmentos (10 classes) – COS 2007. ....	65
Tabela 18: Resultado da matriz de confusão para a classificação orientada a objetos e a COS 2007 e 2015. ....	75
Tabela 19: Cálculos de erro de omissão, comissão, exatidão do produtor e utilizador para a classificação orientada a objetos e COS 2007. ....	80

Tabela 20: Cálculos de erro de omissão, comissão, exatidão do produtor e utilizador para a classificação orientada a objetos – COS 2015.....	80
Tabela 21: Matriz de confusão para a classificação orientada a objetos, para 10 classes....	92
Tabela 22: Matriz de confusão para a classificação orientada a objetos, para 10 classes....	93
Tabela 23: Matriz de confusão para a classificação orientada a pixel, para 10 classes. ....	94
Tabela 24: Matriz de confusão para a classificação orientada a pixel, para 14 classes. ....	95
Tabela 25: Matriz de confusão para a classificação orientada a segmentos, para 10 classes. .....	96
Tabela 26: Matrizes de confusão para a classificação orientada a segmentos, para 14 classes.....	97
Tabela 27: Matrizes de confusão para a comparação da classificação orientada a objetos com a COS 2007.....	98
Tabela 28: Matrizes de confusão para a comparação da classificação orientada a objetos com a COS 2015.....	99

## GLOSSÁRIO

GEOBIA	Geographic object image analysis
OBIA	Object image analysis
Arcgis	Software de Sistemas de Informação Geográfica
eCognition 9.0	Software de Processamento de Imagens de Satélite
ENVI 5	Software de Processamento de Imagens de Satélite
COS 2007	Carta de ocupação do solo de 2007
Landsat 8	Satélite de média resolução espacial de observação terrestre
IKONOS	Satélite de alta resolução espacial de observação terrestre
GeoEye	Satélite de alta resolução espacial de observação terrestre
NDVI	Normalized Difference Vegetation Index
NDWI	Modification of Normalized Difference Water Index
NN	Vizinho mais próximo (nearest neighbour)
DGT	Direção geral do território

**ANEXO A:** Matrizes de confusão para a classificação orientada a objetos, para 10 e 14 classes.

		Pixéis observados												
		1.1	1.2	1.3	2	3.1	3.2	3.3	4.2	5.1	5.2	Total	Erro de comissão (%)	Exatidão do produtor (%)
Pixéis classificados	1.1	<b>2399836</b>	244522	46200	926346	242784	331352	24007	697	11218	5002	4231964	43,29	51,44
	1.2	126728	<b>396350</b>	17621	103746	81728	112907	5412	233	3508	1455	849688	53,35	52,91
	1.3	6696	9589	<b>104379</b>	8343	28432	26419	4306	0	194	0	188358	44,58	61,77
	2	1618430	109274	48922	<b>13443828</b>	3293828	3725491	146532	1333	45550	1667	22434855	40,08	44,43
	3.1	522937	31255	17831	5238426	<b>11469576</b>	7958094	687136	1538	34031	1134	25961958	55,82	46,55
	3.2	257076	41610	29927	4416783	6072590	<b>15646070</b>	1524371	609	65135	893	28055064	44,23	45,42
	3.3	9515	6590	4463	42636	246566	853847	<b>1106542</b>	30	4432	8288	2282909	51,53	68,41
	4.2	311	88	0	1296	1027	330	8	<b>14998</b>	0	1028	19086	21,42	39,68
	5.1	770	904	3691	10991	20397	13978	955	161	<b>472066</b>	15738	539651	12,52	25,91
	5.2	195	1553	10	151	140	203	3402	5265	1052	<b>15873605</b>	15885576	0,08	0,22
	Total	4942494	841735	273044	24192546	21457068	28668691	3502671	24864	637186	15908810	<b>100449109</b>		
	Erro de omissão (%)	51,44	52,91	61,77	44,43	46,55	45,42	68,41	39,68	25,91	0,22			
	Exatidão do utilizador (%)	56,71	46,65	55,42	59,92	44,18	55,77	48,47	78,58	87,48	99,92			

Tabela 21: Matriz de confusão para a classificação orientada a objetos, para 10 classes.

		Pixéis observados																
		1.1	1.2	1.3	1.4	2.1	2.2	2.3	3.4	3.1	3.2	3.3	4.2	5.1	5.2	Total	Erro de comissão (%)	Exatidão do produtor (%)
Pixéis classificados	1.1	2306685	240667	45425	39559	426674	172500	1633	300316	231018	321393	23729	692	10982	4988	4126261	44,1	47,72
	1.2	121059	396350	17621	5669	53629	19405	262	30450	81728	112907	5412	233	3508	1455	849688	53,35	47,09
	1.3	6168	9589	104379	528	2868	2288	60	3127	28432	26419	4306	0	194	0	188358	44,58	38,23
	1.4	21993	3855	775	31599	10807	4615	0	9801	11766	9959	278	5	236	14	105703	70,11	28,98
	2.1	407783	24749	9847	6314	2671807	430520	4011	1164798	1862116	977385	21015	564	11289	963	7593161	64,81	29,8
	2.2	296635	31264	20036	4921	1069509	4686962	8515	673998	492879	1663411	27944	150	14844	257	8991325	47,87	54,62
	2.3	978	198	49	5	6931	3098	23933	2701	4543	11497	678	0	220	0	54831	56,35	31,68
	2.4	894827	53063	18990	6967	910402	491700	3265	1291678	934290	1073198	96895	619	19197	447	5795538	77,71	19,66
	3.1	515513	31255	17831	7424	2475995	650064	17361	2095006	11469576	7958094	687136	1538	34031	1134	25961958	55,82	53,45
	3.2	251807	41610	29927	5269	1311099	2105563	16410	983711	6072590	15646070	1524371	609	65135	893	28055064	44,23	54,58
	3.3	8989	6590	4463	526	21403	8193	98	12942	246566	853847	1106542	30	4432	8288	2282909	51,53	31,59
	4.2	257	88	0	54	908	0	0	388	1027	330	8	14998	0	1028	19086	21,42	60,32
	5.1	657	904	3691	113	2973	6023	0	1995	20397	13978	955	161	472066	15738	539651	12,52	74,09
	5.2	102	1553	10	93	109	0	0	42	140	203	3402	5265	1052	15873605	15885576	0,08	99,78
	Total	4833453	841735	273044	109041	8965114	8580931	75548	6570953	21457068	28668691	3502671	24864	637186	15908810	100449109		
	Erro de omissão (%)	52,28	52,91	61,77	71,02	70,2	45,38	68,32	80,34	46,55	45,42	68,41	39,68	25,91	0,22			
	Exatidão do utilizador (%)	55,9	46,65	55,42	29,89	35,19	52,13	43,65	22,29	44,18	55,77	48,47	78,58	87,48	99,92			

Tabela 22: Matriz de confusão para a classificação orientada a objetos, para 10 classes.



**ANEXO B:** Matrizes de confusão para a classificação orientada a pixel, para 10 e 14 classes.

		Pixéis observados												
		1.1	1.2	1.3	2	3.1	3.2	3.3	4.2	5.1	5.2	Total	Erro de comissão (%)	Exatidão do produtor (%)
Pixéis classificados	1.1	<b>1695096</b>	287390	34005	211239	80702	105731	9139	352	3980	5598	2433232	30,34	34,23
	1.2	377131	<b>254727</b>	91463	1968696	209357	599826	51447	933	43142	278906	3875628	93,43	30,17
	1.3	582	315	<b>158</b>	255	85	160	25	0	5	0	1585	90,03	0,06
	2	2482879	180828	76019	<b>16084226</b>	6261135	11185213	691267	9376	70406	2770	37044119	56,58	66,27
	3.1	59377	9844	10171	1639294	<b>10532794</b>	4292381	221589	9981	70453	5075	16850959	37,49	48,92
	3.2	208496	26399	21936	4047317	4115563	<b>12076247</b>	1925463	2063	39768	1615	22464867	46,24	41,98
	3.3	117995	81258	35670	235959	249522	399817	<b>602409</b>	1870	9154	1448	1735102	65,28	17,19
	4.2	3	0	52	1	0	7	2	<b>14</b>	15268	19575	34922	99,96	0,06
	5.1	193	797	3557	2838	1352	5114	462	267	<b>384575</b>	55864	455019	15,48	60,33
	5.2	0	49	9	1	3	3	3	1	21	15530984	<b>15531074</b>	0	97,22
	Total	4952280	844322	273386	24270123	21531847	28765644	3504536	25168	637432	15901835	100706573		
	Erro de omissão (%)	65,77	69,83	99,94	33,73	51,08	58,02	82,81	99,94	39,67	2,78			
	Exatidão do utilizador (%)	69,66	6,57	9,97	43,32	62,51	53,76	34,72	0,04	84,52	100			

Tabela 23: Matriz de confusão para a classificação orientada a pixel, para 10 classes.

		Pixéis observados																
		1.1	1.2	1.3	1.4	2.1	2.2	2.3	2.4	3.1	3.2	3.3	4.2	5.1	5.2	Total	Erro de comissão (%)	Exatidão do produtor (%)
Pixéis classificados	1.1	1665454	285194	33444	23512	103112	26443	611	74207	79425	104206	9121	352	3969	5594	2414644	31,03	34,39
	1.2	354888	254727	91463	22243	731749	1021176	3777	211994	209357	599826	51447	933	43142	278906	3875628	93,43	30,17
	1.3	539	315	158	43	60	123	0	72	85	160	25	0	5	0	1585	90,03	0,06
	1.4	5243	2196	561	887	4283	671	12	1900	1277	1525	18	0	11	4	18588	95,23	0,81
	2.1	1260486	99739	40934	30676	2685973	707140	6199	1852009	1907040	1441539	74389	6629	17770	1884	10132407	73,49	29,85
	2.2	467436	29807	18516	6708	2240327	5163987	21300	1614656	2208280	4818637	212536	353	45604	672	16848819	69,35	59,96
	2.3	2465	574	1543	108	144815	257056	6477	128551	1221094	4334392	263264	2	2403	0	6362744	99,9	8,54
	2.4	704737	50708	15026	10263	676685	145411	2117	431523	924721	590645	141078	2392	4629	214	3700149	88,34	6,55
	3.1	55595	9844	10171	3782	637257	145165	7697	849175	10532794	4292381	221589	9981	70453	5075	16850959	37,49	48,92
	3.2	204782	26399	21936	3714	1650190	1041363	26462	1329302	4115563	12076247	1925463	2063	39768	1615	22464867	46,24	41,98
	3.3	110983	81258	35670	7012	88442	70561	895	76061	249522	399817	602409	1870	9154	1448	1735102	65,28	17,19
	4.2	0	0	52	3	0	1	0	0	0	7	2	14	15268	19575	34922	99,96	0,06
	5.1	160	797	3557	33	634	1560	1	643	1352	5114	462	267	384575	55864	455019	15,48	60,33
	5.2	0	49	9	0	0	1	0	0	3	3	3	1	21	15530984	15531074	0	97,22
	Total	4842679	844322	273386	109601	8998069	8612037	75876	6584141	21531847	28765644	3504536	25168	637432	15975287	100780025		
	Erro de omissão (%)	65,6	69,83	99,94	99,19	70,15	40,04	91,46	93,45	51,08	58,02	82,81	99,94	39,67	2,78			
	Exatidão do utilizador (%)	68,97	6,57	9,97	4,77	26,51	30,65	0,1	11,66	62,51	53,67	34,72	0,04	84,52	100			

Tabela 24: Matriz de confusão para a classificação orientada a pixel, para 14 classes.

## ANEXO C: Matrizes de confusão para a classificação orientada a segmentos, para 10 e 14 classes.

		Pixéis observados												
		1.1	1.2	1.3	2	3.1	3.2	3.3	4.2	5.1	5.2	Total	Erro de comissão (%)	Exatidão do produtor (%)
Pixéis classificados	1.1	<b>624863</b>	181769	42372	589649	255689	204704	28731	462	4545	3414	1936198	67,73	12,62
	1.2	534514	<b>312910</b>	53401	329338	111552	151500	25418	568	15801	11440	1546442	79,77	37,06
	1.3	17306	27742	<b>12825</b>	4405	3354	5863	5869	47	15	1948	79374	83,84	4,69
	2	3245934	208657	91432	<b>14503778</b>	5467117	9385327	1295587	7764	51223	2623	34259442	57,66	59,76
	3.1	98207	5266	3784	3447734	<b>5163324</b>	2635781	101904	2964	13181	165	11472310	54,99	23,98
	3.2	240841	71789	38177	4545809	10071832	<b>15349138</b>	1460882	6234	75762	32681	31893145	51,87	53,36
	3.3	175352	28489	22945	756472	357355	910274	<b>579256</b>	2046	3482	2382	2838053	79,59	16,53
	4.2	462	708	626	2052	7124	7351	497	<b>2726</b>	3697	747	25990	89,51	10,83
	5.1	3264	2334	5465	9524	14296	12651	1566	1740	<b>426723</b>	56896	534459	20,16	66,94
	5.2	1151	1850	1921	1066	837	2394	2380	309	42626	<b>15792898</b>	15847432	0,34	98,86
	Total	4952280	844322	273386	24270123	21531847	28765644	3504536	25168	637432	15975287	<b>100780025</b>		
	Erro de omissão (%)	87,38	62,94	95,31	40,24	76,02	46,64	83,47	89,17	33,06	1,14			
	Exatidão do utilizador (%)	32,27	20,23	16,16	42,34	45,01	48,13	20,41	10,49	79,84	98,86			

Tabela 25: Matriz de confusão para a classificação orientada a segmentos, para 10 classes.

		1.1	1.2	1.3	1.4	2.1	2.2	2.3	2.4	3.1	3.2	3.3	4.2	5.1	5.2	Total	Erro de comissão (%)	Exatidão do produtor (%)
Pixéis classificados	1.1	<b>538254</b>	179583	41463	15542	69182	71059	1062	26795	51070	116321	26844	165	3927	3390	1144657	52,98	11,14
	1.2	520214	<b>320726</b>	53688	19892	100753	151378	441	75224	104176	145791	25188	631	16523	11872	1546497	79,26	38,11
	1.3	15117	28248	<b>13054</b>	2137	1972	1141	17	1125	2985	5660	5939	42	20	1925	79382	83,56	4,78
	1.4	66409	4796	1440	<b>4751</b>	248914	27219	68	149973	200498	84726	1879	290	466	193	791622	99,4	4,36
	2.1	566815	24123	12241	8292	<b>735121</b>	213686	1841	422980	280184	412802	233619	1160	2733	372	2915969	74,79	8,2
	2.2	1137572	53908	37143	11955	2946461	<b>5222103</b>	22206	2069754	2786602	6146525	780845	1499	32264	382	21249219	75,42	60,86
	2.3	672	428	562	51	25898	39384	<b>625</b>	23460	327027	1319535	113123	0	559	0	1851324	99,97	0,83
	2.4	1524478	128676	42100	21300	1369171	432213	4126	<b>1115383</b>	1969878	1449285	167978	5084	14906	1664	8246242	86,47	16,97
	3.1	79867	3848	3618	4100	1724424	286571	14039	1390892	<b>5218978</b>	2634477	98864	2996	11237	46	11473957	54,51	24,32
	3.2	209127	64431	36434	12911	1568683	1677719	28433	1156404	10142213	<b>15427680</b>	1463177	6232	71699	32898	31898041	51,63	53,81
	3.3	172436	28217	23199	6170	171428	452660	2647	136647	351111	904727	<b>581096</b>	2062	3934	2334	2838668	79,53	16,59
	4.2	251	554	587	182	359	1152	40	410	7492	7432	481	<b>2800</b>	3555	712	26007	89,23	11,26
	5.1	1637	2391	5517	1398	2503	4040	3	1890	14179	11699	1559	1617	<b>431889</b>	57465	537787	19,69	67,78
	5.2	506	1695	1914	360	234	601	0	3	665	2006	2080	286	43474	<b>15795568</b>	15849392	0,34	99,29
	Total	4833355	841624	272960	109041	8965103	8580926	75548	6570940	21457058	28668666	3502672	24864	637186	15908821	<b>100448764</b>		
	Erro de omissão (%)	88,86	61,89	95,22	95,64	91,8	38,14	99,17	88,03	75,68	46,19	83,41	88,74	32,22	0,71			
	Exatidão do utilizador (%)	47,02	20,74	16,44	0,6	25,21	24,58	0,03	13,53	45,49	48,37	20,47	10,77	80,31	99,66			

Tabela 26: Matrizes de confusão para a classificação orientada a segmentos, para 14 classes.

## ANEXO D: Matrizes de confusão para a Classificação orientada a objetos – carta de ocupação do solo de 2007.

		Pixéis observados																
		1.1	1.2	1.3	1.4	2.1	2.2	2.3	2.4	3.1	3.2	3.3	4.2	5.1	5.2	Total	Erro de comissão (%)	Exatidão do produtor (%)
Pixéis classificados	1.1	44268	1568	701	840	5914	520	17	3184	2568	1482	404	346	18	175	62005	28.61	43.05
	1.2	2391	9714	311	79	2334	13	0	523	3252	542	34	93	0	13	19299	49.67	61.68
	1.3	32	45	1897	0	88	0	0	0	141	0	0	0	0	0	2203	13.89	40.38
	1.4	499	124	0	741	216	6	0	15	533	24	0	4	0	11	2173	65.90	31.88
	2.1	13972	1504	339	110	70728	1342	4	21125	28960	3530	249	213	12	72	142160	50.25	45.14
	2.2	289	28	15	67	174	6	0	50	160	31	21	0	0	0	841	99.29	0.11
	2.3	16	0	0	0	80	4	33	0	0	0	0	0	0	0	133	75.19	56.90
	2.4	25672	1717	661	153	19133	494	4	40621	15221	1734	248	313	46	98	106115	61.72	43.85
	3.1	11699	682	498	167	55388	2610	0	26075	194643	7471	688	18	541	102	300582	35.24	74.77
	3.2	3617	192	227	59	2030	418	0	902	13921	1097	224	17	63	29	22796	95.19	6.49
	3.3	219	17	49	29	498	23	0	129	508	869	5274	0	31	551	8197	35.66	63.64
	4.2	118	45	0	55	3	0	0	12	177	115	8	2003	0	64	2600	22.96	44.58
	5.1	10	2	0	15	31	0	0	2	214	14	9	21	2045	1582	3945	48.16	74.20
	5.2	24	112	0	9	58	0	0	0	26	0	1128	1465	0	62889	65711	4.29	95.89
	Total	102826	15750	4698	2324	156675	5436	58	92638	260324	16909	8287	4493	2756	65586	738760		
	Erro de omissão (%)	56.95	38.32	59.62	68.12	54.86	99.89	43.10	56.15	25.23	93.51	36.36	55.42	25.80	4.11			
	Exatidão do utilizador (%)	71.39	50.33	86.11	34.10	49.75	0.71	24.81	38.28	64.76	4.81	64.34	77.04	51.84	95.71			

Tabela 27: Matrizes de confusão para a comparação da classificação orientada a objetos com a COS 2007.



## ANEXO E: Matrizes de confusão para a Classificação orientada a objetos - Carta de ocupação do solo de 2015.

		Pixéis observados																
		1.1	1.2	1.3	1.4	2.1	2.2	2.3	2.4	3.1	3.2	3.3	4.2	5.1	5.2	Total	Erro de comissão (%)	Exatidão do produtor (%)
Pixéis classificados	1.1	41410	2486	855	880	9601	158	18	1966	3278	507	285	318	13	161	61936	33.14	44.63
	1.2	2549	10003	68	239	3014	24	0	534	2526	175	24	96	3	2	19257	48.06	53.82
	1.3	0	31	1842	0	211	0	0	0	119	0	0	0	0	0	2203	16.39	41.83
	1.4	580	91	0	204	210	0	0	587	392	63	0	2	44	0	2173	90.61	9.82
	2.1	13173	2034	539	180	84212	581	0	10588	28502	1405	214	149	34	47	141658	40.55	42.44
	2.2	269	87	8	105	133	0	0	89	116	19	15	0	0	0	841	100.00	0.00
	2.3	10	0	0	0	101	0	20	0	2	0	0	0	0	0	133	84.96	44.44
	2.4	21214	2023	469	163	28500	853	7	37079	13560	1398	393	46	119	13	105837	64.97	52.49
	3.1	9723	1209	271	225	68899	2424	0	18725	190031	7579	60	21	757	24	299948	36.65	75.44
	3.2	3367	505	314	61	2891	292	0	785	12174	2283	42	0	47	1	22762	89.97	16.13
	3.3	312	36	38	1	522	23	0	241	556	450	5020	26	134	822	8181	38.64	76.82
	4.2	142	11	0	0	84	0	0	13	120	201	21	1955	0	53	2600	24.81	46.63
	5.1	0	0	0	3	22	0	0	30	528	9	17	47	3285	0	3941	16.65	74.05
	5.2	34	69	0	16	33	0	0	0	0	68	444	1533	0	63371	65568	3.35	98.26
	Total	92783	18585	4404	2077	198433	4355	45	70637	251904	14157	6535	4193	4436	64494	737038		
	Erro de omissão (%)	55.37	46.18	58.17	90.18	57.56	100.00	55.56	47.51	24.56	83.87	23.18	53.37	25.95	1.74			
	Exatidão do utilizador (%)	66.86	51.94	83.61	9.39	59.45	0.00	15.04	35.03	63.35	10.03	61.36	75.19	83.35	96.65			

Tabela 28: Matrizes de confusão para a comparação da classificação orientada a objetos com a COS 2015.